



Impacto de la variabilidad y cambio climático en la productividad de trigo de invierno mediante modelos agroclimáticos

Tesis doctoral

Sara Hernández Barrera



VNiVERSiDAD
DSALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL



VNiVERSiDAD
D SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL



800 AÑOS
VNiVERSiDAD
D SALAMANCA

1218 - 2018

Departamento de Física Fundamental

Impacto de la variabilidad y cambio climático en la productividad de trigo de invierno mediante modelos agroclimáticos

Memoria presentada para optar al grado de Doctor en Ciencias Físicas por:

SARA HERNÁNDEZ BARRERA

Julio de 2017

Cubierta y fotografías: Depositphotos



VNiVERSiDAD
D SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL



800 AÑOS
VNiVERSiDAD
D SALAMANCA

1218 - 2018

Departamento de Física Fundamental

Impacto de la variabilidad y cambio climático en la productividad de trigo de invierno mediante modelos agroclimáticos

Memoria presentada para optar al grado de Doctor en Ciencias Físicas por

Sara Hernández Barrera,

bajo la dirección de Dr D^a Concepción Rodríguez Puebla

La doctoranda

Visto bueno de la Directora

Salamanca, julio de 2017

Agradecimientos

Agradecimientos

Estas líneas van dedicadas a todas aquellas personas, que de una manera u otra, han hecho posible la realización de esta tesis doctoral y que gracias a ellas, esta experiencia ha merecido la pena.

Durante mis años de doctorado, a pesar de ser los más difíciles de mi vida por motivos familiares, he tenido la grandísima suerte de aprender muchas cosas, vivir nuevas experiencias, de viajar y conocer a muchas personas, y todo gracias a Concha. Sin ella nada de esto hubiera sido posible. Muchas gracias por haberme dado la oportunidad de trabajar a tu lado, por tu dedicación y preocupación constante por mi formación como investigadora, por tu paciencia conmigo en los momentos difíciles. Gracias Concha por transmitirme tu afán de superación, y por el trabajo bien hecho y desinteresado. No tengo suficientes palabras para expresar mi gratitud y aprecio por ti, porque además de tu gran profesionalidad, eres una gran persona que siempre te has preocupado por mi y por mi futuro, a pesar de haber comenzado una nueva etapa de tu vida. Por todo ello, MUCHAS GRACIAS.

A mis padres, a mi abuela Lele y al resto de mi familia, gracias por estar siempre a mi lado a pesar de la distancia. En especial a mi MADRE, a quien dedico esta Tesis, gracias mamá por tu ayuda y apoyo en los momentos más difíciles, porque sin ti no hubiera llegado tan lejos.

A mis amigas de siempre Ainhoa, Elba, Eva, Jesi, Judith y Yaiza, a los que llegaron más tarde a mi vida Alba, Elda, Saray, Will,... porque a pesar de los cientos de kilómetros que nos separan, siempre los he sentido cerca de mi. Gracias por estar siempre ahí, a pesar del paso de los años, y por tener siempre unas palabras de aliento cuando lo necesito. Albi, gracias por tu ayuda

Agradecimientos

desinteresada con mi inglés a lo largo de estos años. Y no puedo olvidarme de las nuevas amistades que he hecho en estos años en Salamanca, gracias Gema, Isa, María, Marina, Sam, Sara, Vero y Wassi por convertíos en mi pequeña familia salmantina y ayudarme a que la añoranza por mis padres, amigos y por mi islita sea más llevadera.

Me gustaría darle las gracias a Nube, mi compañera de despacho durante mis primeros años de doctorado, con quien he compartido grandes momentos, dentro y fuera de la Universidad. Gracias por tu ayuda, por haberme acogido y por hacerme sentir como en casa. A Ascensión por ayudarme en mis comienzos con R. También me gustaría agradecerle a Ana su ayuda desinteresada a pesar de conocerme poco.

I am grateful to Professor Andrew J. Challinor and The Climate Impact group from School of Earth and Environment of the University of Leeds, for hosting me during my research visit. Andrew thank you very much for your advices, for give me the opportunity to uses the winter wheat version GLAM, and to attend and participe in your seminars about of crop models and food security. Thank to all people of The Climate Impact group, in specially to Stewart Jennings for your fast responses, for helping me with GLAM and to fit in the group. I would also like to thank those people that I met at Leeds and with whom I shared my free time. It was a pleasure to meet you all.

Gracias al proyecto de investigación CGL2011-23209 del Ministerio de Economía y Competitividad, el cuál ha permitido comprar material informático para llevar a cabo esta investigación, realizar cursos para completar mi formación, así como asistir a congresos para difundir algunos de los resultados obtenidos durante los años de doctorado. Y en especial, gracias a la concesión de la la beca de Formación del Personal Investigador (FPI) con referencia BES-2012-054447 del Ministerio de Economía y Competitividad, por haberme financiado mis estudios doctorales y permitirme realizar una estancia de investigación en el extranjero.

Me gustaría agradecer también a la Escuela de Doctorado de La Universidad de Salamanca, al coordinador del programa de doctorado en Física Aplicada y Tecnología, Luis Plaja Rustein por su ayuda con el papeleo y con la administración, asimismo, por tenernos siempre informados de los seminarios, cursos y ayudas convocadas. A Alfredo por sus ánimos y ayuda desinteresada. Al departamento de Física General y de la Atmósfera, anexionado al departamento de Física Fundamental, donde se ha realizado esta tesis doctoral, por facilitarme un lugar de trabajo durante estos años. También me gustaría darle

Agradecimientos

las gracias al Vicerrectorado de Investigación y transferencia por financiarme la asistencia al congreso internacional European Geosciences Union (EGU) General Assembly 2017, para recibir el premio a la mejor contribución de joven investigador.

Asimismo, me gustaría agradecerle al Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente por facilitar los datos del rendimiento de trigo.

I would like to acknowledge the observational data providers in the ECA&D project, the EU-FP6 project ENSEMBLES for the E-OBS data set, the ECMWF for ERA-interim reanalysis, the NCEP/NCAR for providing the Extended reconstructed SST and the NOAA Earth System Research Laboratory (ESRL) for the teleconnection indices. I would like to thank the U.S. Department of Energy's Program for Climate Model Diagnosis and Intercomparison provided CMIP5 data. I also acknowledge the developers of GrADS, CDO, NCL, MATLAB and R software.

A todos, muchísimas gracias.

Resumen

En las últimas décadas, el estudio del impacto de la variabilidad y el cambio climático en la agricultura es un tema de investigación relevante. Particularmente, en España los impactos del cambio climático en las producciones agrícolas son preocupantes debido a los resultados obtenidos en el proyecto PESETA II¹, que predice una reducción del 20% en las producciones agrícolas en el sur de Europa a finales del siglo XXI. Dentro de las producciones agrícolas de España, el trigo es de gran interés ya que es un alimento básico y su producción es tan abundante como la de las olivas, los cítricos y viñedos. Sin embargo, la influencia de la meteorología en el trigo ha sido estudiada sólo en zonas puntuales para el clima presente.

En este trabajo de investigación se analiza la variabilidad de la productividad del trigo en España considerando la influencia de la variabilidad climática. Las relaciones obtenidas permiten elaborar modelos que tienen utilidad para proporcionar servicios de predicción en el sector agrario. Asimismo, los resultados permiten proyectar la productividad de trigo bajo el calentamiento global mediante la combinación de los modelos agrícolas con los datos derivados de los modelos de circulación general del Proyecto de Intercomparación de Modelos Acoplados (CMIP).

El objetivo principal de la tesis es obtener modelos agroclimáticos que expliquen la variabilidad del rendimiento de trigo en España, y puedan ser aplicados para proyectar las tendencias del rendimiento del trigo bajo diferentes condiciones climáticas. El trabajo se ha realizado desde las perspectivas empírica

¹Todos los acrónimos utilizados en el Resumen están definidos en la “Lista de acrónimos” en la página XXXIII

y teórica. El estudio empírico se desarrolló mediante un análisis minucioso de la búsqueda de variables climáticas que mejor describen la variabilidad del rendimiento de trigo. Para ello, por un lado, se han utilizado datos climáticos pseudo-observados E-OBS: precipitación, del que se deriva el Índice de Precipitación Estandarizado (SPI) para caracterizar el proceso de sequía; temperatura media, máxima y mínima, de los que se deriva el rango diurno de temperatura (DTR). Por otro lado, se han utilizado datos de reanálisis: radiación solar en superficie (SSRD), la altura geopotencial al nivel de 500 hPa (Z500), la presión al nivel del mar (MSL), el viento horizontal a 250 hPa (U250) pertenecientes al reanálisis ERA-Interim y la temperatura superficial del mar (SST) ERSST (Extended Reconstructed Sea Surface Temperature). Los modelos empíricos se analizan conjuntamente con modelos teóricos basados en los procesos físicos que describen la dinámica del cultivo. Para esta parte de la investigación, se ha utilizado el modelo “The general large-area model (GLAM) for annual crops”. Las diferencias entre las simulaciones empíricas y teóricas se explican mediante diferentes efectos de las teleconexiones climáticas. Por ello una de las conclusiones de gran interés que se deduce del trabajo es la mejora de las proyecciones de productividad de trigo mediante la utilización conjunta de modelos empíricos y basado en procesos.

Dentro de las innovaciones que incluye esta investigación destacamos la incorporación de métodos estadísticos para caracterizar y justificar la variabilidad de las producciones agrícolas. Por ejemplo, la descomposición empírica en modos por conjuntos (EEMD), este método permite filtrar la componente de tendencia no lineal del rendimiento de trigo observado y de las proyecciones de trigo simulado a partir de los modelos CMIP5. Otro método utilizado es la regresión de mínimos cuadrado parciales (PLS) para identificar la co-variabilidad entre las variables climáticas y el rendimiento del trigo, y para obtener proyecciones empíricas de productividad de trigo en condiciones de cambio climático. Además, se ha aplicado el método de análisis de conglomerado de K-medias para identificar regiones con variabilidad de trigo similar. Asimismo se han utilizado otros métodos estadísticos clásicos en el ámbito de la climatología, como la regresión lineal múltiple, test de tendencias y diferentes test de significación.

De todo el trabajo desarrollado en esta investigación destacamos los resultados que se reflejan en tres publicaciones científicas, los cuales se detallan a continuación:

1. Efectos del rango térmico diario y sequía en la productividad del trigo en España (Hernández-Barrera et al. 2016).

En este estudio se evalúan las relaciones entre el rendimiento de trigo y las variables climáticas básicas, y derivadas de la temperatura y precipitación en las diferentes estaciones que abarcan desde la siembra a la cosecha del trigo. El modelo agroclimático obtenido cuantifica los efectos positivos de la precipitación, representados por el SPI, en primavera (MAM) y otoño (SON), y el efecto negativo del DTR en invierno (DJF). Este modelo agroclimático explica un 63 % de la variabilidad del rendimiento de trigo en España. Asimismo, este modelo se aplica a las salidas de los modelos CMIP5 para proporcionar las simulaciones y proyecciones del rendimiento del trigo, de modo que las proyecciones a lo largo del siglo XXI predicen una disminución del rendimiento del trigo. La disminución del rendimiento del trigo queda justificada por la disminución del SPI y el aumento del DTR a lo largo del siglo XXI en España.

2. El rendimiento del trigo en España y su asociación con los patrones de radiación solar (Hernández-Barrera & Rodríguez-Puebla 2017).

Las proyecciones de precipitación dada por los modelos CMIP5 presentan ciertas incertidumbres. Estas imprecisiones han sido demostradas por diversos estudios, que además indican que las variables a gran escala proyectan menos incertidumbres que las variables a escala regional. Por estos motivos, nos planteamos este estudio basado en la influencia de variables a gran escala en la productividad de trigo. Las variables consideradas son la SSRD, la Z500, la MSL, el U250 y la SST. Tras la aplicación de la regresión PLS, se obtiene que la SSRD es la variable que mejor caracteriza la variabilidad de la productividad del trigo, a lo largo de las fases de crecimiento y desarrollo del trigo. Además, la SSRD incluye los efectos de las teleconexiones: la componente PLS de SSRD en invierno está asociada con los índices de teleconexión de la NAO y el EA; la componente PLS de SSRD en primavera está correlacionada con el índice de SCAND; y la componente PLS de SSRD en otoño muestra señales de la AMO. Por lo tanto, el modelo agroclimático se construye a partir de las componentes SSRD. Este modelo describe más varianza de la variabilidad del trigo que el modelo basado en SPI y DTR, explica un 71 % frente al 63 % y además, se aplica para determinar las proyecciones del rendimiento del trigo utilizando las salidas de los

modelos CMIP5. Las proyecciones también predicen una disminución del rendimiento del trigo. La incertidumbre de las diferentes proyecciones se analiza en función de la variabilidad interna y señal contenida en cada tipo de proyección, indicando mayor confianza para la tendencia en el caso del modelo basado en SSRD que en el basado en SPI y DTR.

- 3. Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España (en revisión).** Los modelos agroclimáticos basados en procesos facilitan información sobre la sensibilidad de las producciones al cambio climático. Una de las ventajas de los modelos basados en procesos es que no presentan la limitación de los empíricos en relación a los parámetros de regresión, que se consideran estacionarios en condiciones de calentamiento global. Con esta idea y porque el uso de diferentes modelos permite incrementar la confianza de las proyecciones, se realiza este estudio para complementar así las investigaciones empíricas. La evaluación del modelo de GLAM para caracterizar el rendimiento del trigo se lleva a cabo en cada provincia con datos meteorológicos diarios de la provincia, y en áreas más grandes, en las que el rendimiento de trigo fue clasificado tras aplicar el método de análisis de conglomerado de K-medias. Las simulaciones se comparan con los rendimientos observados en cada provincia. Además de la calibración del modelo GLAM por los procedimientos del propio modelo, aplicamos una re-calibración mediante un ajuste de distribución frecuencial empírico (eQM). Para la evaluación de GLAM-trigo introducimos un método novedoso que consiste en la comparación de la respuesta del trigo observado (OBS-trigo) y el simulado mediante el modelo GLAM a los factores climáticos. Las discrepancias entre ambos tipos de modelos se justifican en el contexto de la diferente influencia de las teleconexiones climáticas. Los resultados inducen a utilizar conjuntamente el modelo GLAM y los empíricos para proporcionar proyecciones con menor incertidumbre.

Summary

Summary

In recent decades, investigating the role of climate variability and change in crop productions has become a highly relevant research topic. Particularly in Spain, there is a concern about the impacts of climate change on crops variability owing to the results obtained in the PESETA II² project, which showed a reduction of around 20% in agricultural production in Southern Europe by the end of the twenty-first century. Wheat is one of Spain's most important crops, as it is basic and necessary food, and its productivity is comparable to that of olive, citrus and grapes. Nevertheless, the influence of climate on wheat yield in Spain has only been evaluated in particular locations for the present-day climate.

In this research, wheat yield variability in Spain is analysed considering the influence of climate variability. The relationships obtained allow models to be drawn up which are useful for sectors that used seasonal predictions in order to provide forecasting services for the agricultural sector. In addition, the results make it possible to project wheat yield under global warming by combining of agricultural models with the outputs of general circulation models from the Coupled Models Intercomparison Project (CMIP).

The main objective of this dissertation was to obtain agro-climate models, which explain wheat yield variability in Spain and can be applied to project wheat yield trends under different climate conditions. This study was based on both empirical and theoretical approaches. The empirical analysis examined the role of climate variables to describe wheat yield variability. To this end, on one hand, the daily pseudo-observation E-OBS dataset was used: precipitation,

²Page XXXIII contains a list of acronyms used in this summary.

from which the Standardized Precipitation Index (SPI) is derived to represent the effects of drought, and mean, maximum and minimum temperature, from which the diurnal temperature range (DTR) was derived. On the other hand, reanalysis data were used: surface solar radiation (SSRD), sea level pressure (MSL), geopotential height at 500 hPa (Z500) and zonal wind at 250 hPa (U250) from ECMWFs ERA-Interim reanalysis, and sea surface temperature (SST) from the Extended reconstructed SST. Empirical models were analysed in conjunction with process-based crop models. In this part of the study, the General Large-Area Model (GLAM) for annual crops were employed. The differences between simulations of the empirical and the process-based models are explained through different effects of the teleconnections. Therefore, one of the conclusions of great interest deriving from this research is the use of empirical and process-based models to reduce the uncertainty about the potential impact of climate change on crop productivity.

Based on this premise, this investigation introduces different novel approaches in the area of climate variability to characterize and justify agricultural productions variability. For instance, Ensemble Empirical Mode Decomposition (EEMD) is used to filter out the non-linear trend component of the observed wheat and of the wheat-yield simulated from the CMIP5 models, and Partial Least Squares (PLS) regression is used to identify co-variability between climate variables and wheat yield, and to obtain the wheat yield empirical projections under climate change scenarios. In addition, K-means clustering is used to identify regions with similar wheat variability. Other traditional statistical methods in the fields of climatology, such as multiple linear regression, trend tests and different significance test are also applied.

The most important findings of this research have given rise to three scientific publications, which are detailed as follows:

- 1. Effects of diurnal temperature range and drought on wheat yield in Spain (Hernandez-Barrera et al. 2016).** This study assesses the relationship between wheat yield and basic climate variables derived from temperature and precipitation in different seasons covering the wheat crop from sowing to harvest. The agro-climate model obtained quantifies the positive effect of precipitation in spring (MAM) and autumn (SON), represented by SPI, and the negative effect of DTR in winter (DJF). This agro-climate model explains a 63% of wheat yield variability in Spain. In addition, this model is applied to simulate and

Summary

project wheat yield using GCMs outputs of CMIP5 models. The projections predict a reduction in wheat yield in the twenty-first century. The decreased wheat yield is justified by a decrease in SPI and an increase DTR for the 21st century.

2. Wheat yield in Spain and associated solar radiation patterns (Hernandez-Barrera & Rodriguez-Puebla 2017).

Simulated precipitation from CMIP5 models are subject to great uncertainty. A number of studies have demonstrated these uncertainties, and also show that large-scale variables project less uncertainty than regional climate variables. Therefore, this study directly addresses downscaling the wheat yield using large-scale variables. Potential fields considered are: SSRD, MSL, Z500, U250 and SST. After applying PLS regression, SSRD was found to characterize the wheat-yield variability along its growth and development cycle. Moreover, SSRD introduces the effects of teleconnection patterns: the PLS component of SSRD in winter is associated with the NAO and the EA; the PLS component of SSRD in spring is significantly correlated with the SCAND; and the PLS component of SSRD in autumn shows signals of the AMO. Therefore, the agro-climate model was obtained from the PLS components of SSRD. This model describes greater variance in wheat yield than the model based on SPI and DTR (71 % as opposed to 65 %). This agro-climate model is also used to determine wheat yield projections using outputs of CMIP5 models. The projections indicate less of a reduction that reported by the model based on SPI and DTR. The uncertainty of the different projections is evaluated according to the internal variability and the significant signal of each model.

3. Assessing GLAM-wheat simulation to estimate variability and projected trend of wheat yield in Spain (in review).

Process-based models are useful for determining the sensitivity of crop yields to climate change. Moreover, the use of different models contributes to increasing confidence in the projections. With this in mind, this study was performed to complement empirical analysis. Evaluation of the GLAM model to characterize wheat yield was carried out for individual provinces using weather data, and in two regions where wheat yield da-

ta was classified by applying K-mean cluster analysis. Simulations were compared with the corresponding wheat yield observed in each province. Calibration of the GLAM model was performed following standard procedure and, in addition, by using a re-calibration of the frequency distribution with the empirical quantile mapping approach (eQM). The GLAM-wheat evaluations consist in comparing the responses of both simulated and observed wheat-yield to the main climate drivers. Some discrepancies between the two types of models arise from different responses to teleconnection patterns. The results suggested using GLAM and empirical models to project wheat yield in order to reduce uncertainty.

Contenido

Agradecimientos	I
Resumen	VI
Summary	XI
Lista de figuras	XXI
Lista de tablas	XXV
Prefacio	XXXII
1 Estado del conocimiento	3
1.1 El trigo	5
1.1.1 Morfología del trigo	6
1.1.2 Etapas de desarrollo según la escala de Zadoks	8
1.1.3 Clasificaciones del trigo	11
1.2 El origen del trigo y su historia	13
1.3 El trigo en España	16
1.4 El clima y el trigo	18
1.4.1 Clasificación climática en España	19
1.4.2 El trigo y la temperatura	24
1.4.3 El trigo y la precipitación	28
1.4.4 El trigo y la radiación solar	31
1.5 Modelos agroclimáticos	34
1.5.1 Modelos empíricos	35
1.5.2 Modelos basados en procesos	35
2 Motivación y objetivos	39
2.1 Motivación y objetivos de la investigación	41

3	Datos	47
3.1	Trigo de invierno	49
3.2	Datos climáticos	51
3.2.1	Datos de precipitación y temperatura	51
3.2.2	Datos de reanálisis: ERA-Interim y ERSST v3b	53
3.3	Índices de teleconexión	56
3.4	Datos CMIP5	57
4	Metodología	63
4.1	Métodos de Análisis Estadísticos	65
4.1.1	Descomposición Empírica en modos por conjuntos	65
	a) Estimador de la pendiente de Sen	70
	b) Test de Mann-Kendall	71
4.1.2	Análisis de conglomerados de K-medias	73
	a) Siluetas de los conglomerados	74
4.1.3	Regresión de Mínimos Cuadrados Parciales	75
4.1.4	Regresión lineal múltiple: Regresión Paso a Paso	81
	a) Método de Validación Cruzada	82
	b) Método Bootstrap	83
	c) Test de Durbin-Watson	84
4.1.5	Corrección de sesgos en percentiles o empirical quantile mapping	84
4.2	Métodos de Análisis Gráficos	85
4.2.1	Mapas de correlación	85
	a) Tasa de Falso Descubrimiento	86
4.2.2	Diagramas de cajas	87
4.2.3	Diagramas de Taylor	88
4.3	Modelo agrícola: “The general large-area model (GLAM) for annual crops”	90
4.4	Comparación de modelos empíricos y basado en procesos	100
5	Resultados	103
5.1	Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”	105
5.1.1	Resumen	105
5.1.2	Puntos de partida y recursos	106
5.1.3	Discusión y conclusiones	108

Contenido

5.1.4	Article “Effects of diurnal temperature range and drought on wheat yield in Spain” and Supplementary Material	117
5.2	Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”	138
5.2.1	Resumen	138
5.2.2	Puntos de partida y recursos	138
5.2.3	Discusión y conclusiones	140
5.2.4	Article “Wheat yield in Spain and associated solar radiation patterns” and Supporting Information	149
5.3	Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”	171
5.3.1	Resumen	171
5.3.2	Puntos de partida y recursos	171
5.3.3	Discusión y conclusiones	174
5.3.4	Article “Assessing GLAM-wheat simulation to estimate variability and projected trend of wheat yield in Spain” and Supplementary Material	186
6	Conclusiones y trabajo futuro	227
6.1	Introducción	229
6.2	Conclusiones específicas	231
6.2.1	Efectos del rango térmico diario y sequía en la productividad del trigo en España	231
6.2.2	El rendimiento del trigo en España y su asociación con los patrones de radiación solar	232
6.2.3	Evaluación del modelo agrícola GLAM para caracterizar la variabilidad y tendencia del trigo en España	233
6.3	Futuras líneas de investigación	235
7	Conclusions and future work	239
7.1	Introduction	241
7.2	Specific conclusions	242
7.2.1	Effects of diurnal temperature range and drought on wheat yield in Spain	242
7.2.2	Wheat yield in Spain and associated solar radiation patterns	243
7.2.3	Assessing GLAM-wheat simulation to estimate variability and projected trend of wheat yield in Spain	245

7.3 Future works	246
Referencias	249
Apéndice	280
Apéndice A: Modelos CMIP5	281

Lista de Figuras

Figura 1.1	Morfología de la planta del trigo a lo largo de las etapas de desarrollo	8
Figura 1.2	Etapas de desarrollo del cultivo del trigo según la escala decimal de Zadoks relacionadas con los estados internos del cultivo	11
Figura 1.3	Serie histórica del rendimiento de trigo para toda España para el periodo 1980-2014	16
Figura 1.4	Distribución espacial de la superficie cultivada de trigo en la España Peninsular	17
Figura 1.5	Ciclo anual de precipitación para el periodo 1979-2014	18
Figura 1.6	División territorial de España por provincias	20
Figura 1.7	Clasificación del clima en la PI, según la clasificación de Köppen	21
Figura 1.8	Distribución espacial de la temperatura media (a), máxima (b) y mínima (c) y rango diurno de temperatura (d) en la Península Ibérica para el periodo 1979–2014	26
Figura 1.9	Series temporales de la temperatura mínima de otoño (a), invierno (b), primavera (c) y verano (d) en la España peninsular para el periodo 1979–2014	26
Figura 1.10	Series temporales de la temperatura máxima de otoño (a), invierno (b), primavera (c) y verano (d) en la España peninsular para el periodo 1979–2014	27
Figura 1.11	Series temporales del rango diurno de temperatura de otoño (a), invierno (b), primavera (c) y verano (d) en la España peninsular para el periodo 1979–2014	27
Figura 1.12	Distribución espacial de la precipitación anual en la Península Ibérica para el periodo 1979–2014	29
Figura 1.13	Climogramas para el periodo 1979-2014 en la Península Ibérica (a), Almería (b), La Coruña (c), Salamanca (d), Sevilla (e) y Zaragoza (f)	30

Figura 1.14 Series temporales de la precipitación acumulada de otoño (a), invierno (b), primavera (c) y verano (d) en la España peninsular para el periodo 1979–2014	31
Figura 1.15 Distribución espacial de la radiación solar anual en la Península Ibérica para el periodo 1979-2014	33
Figura 1.16 Ciclo anual de la radiación solar en superficie para diversos lugares de la Península Ibérica	33
Figura 1.17 Series temporales de la radiación solar de otoño (a), de invierno (b), de primavera (c) y de verano (d) en la España peninsular para el periodo 1979–2014	34
Figura 3.1 Distribución espacial del rendimiento de trigo en España	50
Figura 3.2 Serie temporal del rendimiento de trigo espacialmente promediado de las dos regiones para el periodo 1980-2014 . . .	51
Figura 4.1 Serie temporal del rendimiento del trigo observado (a) y de las funciones de modo intrínseco (IMFs) (b-e)	69
Figura 4.2 Serie temporal del trigo simulado (a) y las funciones de modo intrínseco (IMFs) (b-h)	70
Figura 4.3 Representación gráfica de la regresión PLS en el modo temporal (a) y en el modo espacial (b)	80
Figura 4.4 Diagrama de la validación cruzada dejando uno fuera .	82
Figura 4.5 Esquema de un diagrama de Cajas: distribución simétrica (a) y distribución asimétrica (b)	87
Figura 4.6 Esquema de un diagrama Esquemático mostrando los valores atípicos de un conjunto de datos	88
Figura 4.7 Diagrama de Taylor para la precipitación obtenidas con los dos modelos CMIP5 y el multimodelo para el período 1979-2014	90
Figura 4.8 Diagrama esquemático que representa la estructura del modelo GLAM	92
Figura 5.1 Serie temporal del rendimiento del trigo observado y sin tendencia (a), de las componentes de tendencia (b) y las funciones de modo intrínseco (IMFs) (c-e)	109

Lista de Figuras

Figura 5.2	Correlación entre el rendimiento de trigo sin tendencia y las variables climáticas: SPI en otoño (a), SPI en primavera (b), DTR en invierno (c), T_{max} en primavera (d), T_{min} en invierno (e). Gráficos de dispersión que representan el rendimiento de trigo frente a: SPI en otoño (f), SPI en primavera (g), DTR en invierno (h), T_{max} en primavera (i), T_{min} en invierno (j) . . .	110
Figura 5.3	Patrones de la regresión PLS derivados de las series temporales de trigo y los campos climáticos: SPI en otoño (a), SPI en primavera (b) y DTR en invierno (c). Gráficos de dispersión que representan el rendimiento de trigo frente a: SPI en otoño (d) y en primavera (e), DTR en invierno (f)	112
Figura 5.4	Serie temporal del rendimiento del trigo observado y del rendimiento del trigo simulado por el modelo agroclimático . .	113
Figura 5.5	Series temporales de las tendencias filtradas del rendimiento de trigo simulado a partir de los modelos CMIP5 y el multimodelo	114
Figura 5.6	Valores obtenidos del test del estimador de Sen y del test de Mann-Kendall para evaluar los cambios en el rendimiento del trigo en los siglos XX y XXI obtenidos mediante los modelos CMIP5	115
Figura 5.7	Diagrama de Cajas que compara los rendimientos de trigo obtenidos a partir de las salidas de los modelos CMIP5	116
Figura 5.8	Series temporales espacialmente promediadas en España del SPI en otoño (a), SPI en primavera (b) y del DTR en invierno (c) correspondientes a la simulación del multimodelo	117
Figura 5.9	Patrones de la regresión PLS (a-c) derivados de las series temporales de trigo y los campos de la SSRD y las componentes PLS de SSRD (d-f)	142
Figura 5.10	Series temporales del rendimiento de trigo observado y del rendimiento de trigo obtenido con los modelos empíricos para la región 1 (a) y para la región 2 (b)	144
Figura 5.11	Diagrama de dispersión del modelo agroclimático basado en SSRD y del basado en SPI y DTR para la región 1 (a) y para la región 2 (b)	145
Figura 5.12	Series temporales de las tendencias filtradas del rendimiento de trigo simulado a partir de los modelos CMIP5 y el multimodelo: para la región 1 (a) y la región 2 (b)	146

Figura 5.13 Valores obtenidos del test del estimador de Sen y del test de Mann-Kendall para evaluar los cambios en el rendimiento del trigo en los siglos XX y XXI obtenidos mediante los modelos CMIP5 147

Figura 5.14 Diagrama de Cajas que compara los rendimientos de trigo obtenidos a partir de las salidas de los modelos CMIP5 148

Figura 5.15 a) Correlación lineal y error cuadrático medio entre el rendimiento de trigo simulado con GLAM y el observado. b) Las mismas métricas estadísticas después de la re-calibración aplicando eQM 175

Figura 5.16 Diagrama de Taylor que muestra la habilidad de GLAM-trigo en cada provincia y en las regiones 1 y 2 176

Figura 5.17 Series temporales del rendimiento de trigo observado y el simulado por GLAM para España (a), la región 1 (b) y la región 2 (c) 177

Figura 5.18 Diagrama de dispersión que muestran las respuesta del rendimiento de trigo a los diferentes factores climáticos o componentes PLS: radiación solar (SSRD) (a, b, c); índice de precipitación estandarizado (SPI) (d y f); rango diurno de temperatura (e) para la región 1 y región 2 179

Figura 5.19 Mapas compuestos del rendimiento de trigo para los años del ENSO: usando OBS-trigo (a) y usando GLAM-trigo (b) 180

Figura 5.20 Correlación lineal y error cuadrático medio entre el rendimiento de trigo de GLAM_EMP-trigo y OBS-trigo 182

Figura 5.21 Series temporales del rendimiento de trigo observado y el simulado por GLAM_EMP-trigo para España (a), la región 1 (b) y la región 2 (c) 183

Figura 5.22 Proyecciones del rendimiento de trigo para los diferentes modelos CMIP5: usando el modelo GLAM-trigo (a) y el modelo GLAM_EMP-trigo (b). Y las tendencias filtradas de las proyecciones del rendimiento de trigo para GLAM-trigo (c) y para GLAM_EMP-trigo (d) 186

Figura 5.23 Diagrama de Cajas que compara los rendimientos de trigo obtenidos a partir de las salidas de los modelos CMIP5 186

Lista de Tablas

Tabla 1.1 Fases de desarrollo del trigo siguiendo la escala decimal de Zadoks	10
Tabla 1.2 Regionalización climática de España	22
Tabla 3.1 Características de los reanálisis más destacados	55
Tabla 3.2 Modelos CMIP5 utilizados en esta investigación	60
Tabla 4.1 Parámetros modificados con ‘GLAM Optimiser’ para el trigo de invierno y sus rangos	99
Tabla 5.1 Evaluación de las relaciones de modelado a través de: la varianza de las variables independientes y la varianza de la variable dependiente; del coeficiente de determinación antes y después de aplicar la validación cruzada; y de la raíz cuadrada del error cuadrático medio de la regresión PLS	141
Tabla 5.2 Evaluación de las relaciones de modelado a través de: la varianza de las variables independientes y la varianza de la variable dependiente; del coeficiente de determinación antes y después de aplicar la validación cruzada; y de la raíz cuadrada del error cuadrático medio de la regresión PLS	144
Tabla 5.3 Evaluación del modelo lineal entre el rendimiento de trigo observado (OBS) y simulado (GLAM). Y las componentes PLS de la SSRD, utilizando diferentes métricas	178
Tabla 5.4 Evaluación del modelo lineal entre el rendimiento de trigo observado (OBS) y simulado (GLAM) y las componentes PLS del índice de precipitación estandarizado (SPI) y del rango diurno de temperatura (DTR), utilizando diferentes métricas .	178

Tabla 5.5 Cambios en el rendimiento de trigo a lo largo del siglo XXI para España usando el estimador de Sen y el test de Man-Kendall para la significación, para todos los modelos individuales y el multimodelo. Y el cambio relativo y la señal/ruido (SNR) para el multimodelo 185

Lista de acrónimos

20CR	<i>20th Century Reanalysis</i>
AEMet	<i>Agencia Estatal de Meteorología</i>
AMO	<i>Atlantic Multidecadal Oscillation</i>
AOGCM	<i>Atmosphere-Ocean General Circulation Model</i>
APSIM	<i>Agricultural Production Systems Simulator model</i>
APSRU	<i>Agriculture Production Systems Research Unit</i>
CDF	<i>Cumulative Distribution Function</i>
CDO	<i>Climate Data Operator</i>
CEAS	<i>Consejería de Agricultura y Ganadería, Junta de Castilla y León</i>
CERES	<i>Crop Environment REsource Synthesis</i>
CLIVAR	<i>Climate Variability</i>
CMIP1	<i>Coupled Model Intercomparison Project Phase 1</i>
CMIP2	<i>Coupled Model Intercomparison Project Phase 2</i>
CMIP3	<i>Coupled Model Intercomparison Project Phase 3</i>
CMIP5	<i>Coupled Model Intercomparison Project Phase 5</i>
CMIP6	<i>Coupled Model Intercomparison Project Phase 6</i>
CMIP	<i>Coupled Model Intercomparison Project</i>
CO ₂	<i>Dióxido de Carbono</i>
CPC	<i>Climate Prediction Center</i>

CropSyst	<i>Cropping Systems Simulation Model</i>
CV	<i>Cross Validation</i>
DJF	<i>December-January-February</i>
DSSAT	<i>Decision Support System for Agrotechnology Transfer</i>
DTR	<i>Diurnal Temperature Range (Rango Diurno de Temperatura)</i>
DW	<i>Durbin-Watson test</i>
E-OBS	<i>European daily high-resolution gridded data set</i>
EA	<i>East Atlantic pattern</i>
ECMWF	<i>European Centre for Medium-Range Weather Forecasts</i>
EEMD	<i>Ensemble Empirical Mode Decomposition</i>
EMD	<i>Empirical Mode Decomposition</i>
ENSO	<i>El Niño-Southern Oscillation</i>
EOF	<i>Empirical Orthogonal Functions</i>
eQM	<i>Empirical Quantile Mapping</i>
ERA-15	<i>ECMWF Re-Analysis</i>
ERA-40	<i>EECMWF Re-Analysis</i>
ERA-Interim	<i>ECMWF Re-Analysis</i>
ERA5	<i>ECMWF Re-Analysis</i>
ERSST v3b	<i>Extended Reconstructed Sea Surface Temperature - version 3b</i>
ERSST v4	<i>Extended Reconstructed Sea Surface Temperature - version 4</i>
ESRL	<i>Earth System Research Laboratory</i>
EU-FP6	<i>European Union-Sixth Framework Programme for Research and Technological Development</i>
EU-FP7	<i>European Union-Seventh Framework Programme for Research and Technological Development</i>

Lista de acrónimos

EURO4M	<i>European Reanalysis and Observations for Monitoring</i>
FAO	<i>Food and Agriculture Organization of the United Nations</i>
FDR	<i>False Discovery Range</i>
GLAM	<i>The General Large-Area Model</i>
IBSNAT	<i>International Benchmark Sites Network for Agrotechnological Transfer</i>
IMF	<i>Intrinsic Mode Functions</i>
INRA	<i>L'Institut National de la Recherche Agronomique</i>
IPCC	<i>Intergovernmental Panel on Climate Change</i>
IPTS	<i>Institute for Prospective Technological Studies</i>
JRA-55	<i>Japanese 55-year Re-Analysis</i>
JRC	<i>Joint Research Center</i>
JSC/CLIVAR	<i>Joint Scientific Committee/Climate Variability and Predictability</i>
LAI	<i>Leaf Area Index</i>
LOOCV	<i>Leave-One-Out Cross-Validation</i>
MAGRAMA	<i>Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente</i>
MAM	<i>March-April-May</i>
MERRA	<i>Modern-Era Retrospective Analysis for Research and Applications</i>
MK	<i>Mann-Kendall test</i>
MSL	<i>Sea Level Pressure (Presión al Nivel del Mar)</i>
NAO	<i>North Atlantic Oscillation</i>
NCAR	<i>National Center for Atmospheric Research</i>
NCEP	<i>National Centers for Environmental Prediction</i>

Lista de acrónimos

NCL	<i>Near Command Language</i>
NIPALS	<i>Non-linear Iterative Partial Least Squares</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
PCA	<i>Principal Component Analysis</i>
PCMDI	<i>Program for Climate Model Diagnosis and Intercomparison</i>
PESETA	<i>Projection of Economic impacts of climate change in Sectors of the EU based on bottom-up Analysis</i>
PI	<i>Península Ibérica</i>
PLS	<i>Partial Least Squares</i>
RCP	<i>Representative Concentration Pathways</i>
RMSE	<i>Root Mean Square Error</i>
RPCA	<i>Rotated Principal Component Analysis</i>
S2S	<i>Subseasonal to Seasonal</i>
SCAN	<i>Scandinavia pattern</i>
SIMPLS	<i>Straightforward Implementation of a statistically inspired Modification of the PLS</i>
SNR	<i>Signal to Noise Ratio</i>
SON	<i>September-October-November</i>
SPI	<i>Standardized Precipitation Index (Índice de Precipitación Estandarizado)</i>
SSRD	<i>Surface Solar Radiation (Radiación Solar en Superficie)</i>
SST	<i>Sea Surface Semperature (Temperatura Superficial del Mar)</i>
STICS	<i>Standard mulTIdisciplinary Simulator for Crops</i>
T_{max}	<i>Minimum Temperature (Temperatura máxima)</i>
T_{mean}	<i>Mean Temperature (Temperatura media)</i>
T_{min}	<i>Maximum Temperature (Temperatura mínima)</i>
XXX	

Lista de acrónimos

TPS	<i>Thin Plate Splines</i>
TP	<i>Tallo Principal</i>
U250	<i>Zonal Wind at 250 hPa (Viento Horizontal a 250 hPa)</i>
UERRA	<i>Uncertainties in Ensembles of Regional ReAnalyses</i>
WCRP	<i>World Climate Research Program</i>
WGCM	<i>Working Group on Coupled Modelling</i>
YGP	<i>Yield Gap Parameter</i>
Z500	<i>Geopotential height at 500 hPa (Altura Geopotencial al nivel de 500 hPa)</i>

Prefacio

Los modelos agrícolas constituyen la herramienta necesaria para abordar el problema del impacto del cambio climático en la agricultura. Los modelos se suelen agrupar en basados en procesos y estadísticos o empíricos, atendiendo al método utilizado para su elaboración. Los modelos basados en procesos tratan de representar los procesos dinámicos que afectan al crecimiento del cultivo, mientras que los modelos estadísticos utilizan las relaciones históricas entre la productividad del cultivo y las observaciones meteorológicas.

En España, existe un gran interés nacional por las producciones agrícolas, entre las que podemos destacar el trigo. A pesar de ello, los efectos de las variaciones climáticas en el trigo sólo han sido estudiadas en regiones puntuales (Gimeno et al. 2002, Vicente-Serrano et al. 2006, Iglesias & Quiroga 2007, Rodríguez-Puebla et al. 2007, Ruiz-Ramos et al. 2011). Un aspecto relevante de la investigación desarrollada es que analiza la influencia del cambio climático en la productividad de trigo en España mediante el uso de diferentes datos y aplicando diferentes metodologías. Dentro de este contexto, en esta investigación se utilizan modelos agrícolas basados en procesos y estadísticos para analizar los efectos de las variables climáticas en el trigo.

La investigación fue compleja por diversos motivos. Por una parte, para identificar las variables climáticas que directa o indirectamente se encuentran asociadas a las variaciones de productividad de trigo. Por otra parte, para mostrar proyecciones teniendo en consideración el grado de incertidumbre de las proyecciones de los modelos climáticos. Por todo ello, fue necesario ensayar diferentes métodos estadísticos y adaptarlos de forma novedosa para el desarrollo

de este trabajo. Dentro de la investigación destacamos las siguientes fases de gran interés:

- ◇ La identificación de la sequía y el rango diurno de temperaturas como procesos climáticos locales más importantes que afectan a la producción de trigo.
- ◇ La identificación de la radiación solar como modo de variabilidad a gran escala que explica la influencia de los procesos locales y teleconexiones climáticas en el rendimiento del trigo.
- ◇ La puesta a punto del modelo agrícola GLAM³ en relación a la calibración y evaluación del modelo para caracterizar la productividad anual del trigo en España.
- ◇ El estudio comparativo y el análisis de las diferencias de los modelos empíricos y GLAM.
- ◇ La determinación de proyecciones de productividad de trigo en condiciones de cambio climático y el análisis de sus incertidumbres.

Esta investigación ha sido realizada dentro del grupo de investigación GICA⁴, perteneciente a la facultad de Ciencias de la Universidad de Salamanca. La investigadora principal de este grupo de investigación, Concepción Rodríguez Puebla, es la directora de esta tesis doctoral. La financiación para realizar esta investigación se enmarca dentro del proyecto de investigación CGL2011-23209, con título “Análisis de Extremos Climáticos Mediante Teleconexiones y Evaluación de Modelos Climáticos CMIP5⁵. Impacto de las Variaciones en Producciones Agrícolas”, concedido por el Ministerio de Economía y Competitividad, con una beca asociada de Formación del Personal Investigador (FPI) de referencia BES-2012-054447.

Los resultados obtenidos en esta tesis doctoral han dado lugar a tres artículos publicados en revistas de impacto científico: 1) publicado en la revista *Theoretical and Applied Climatology* con título “Effects of diurnal temperature range and drought on wheat yield in Spain” (Hernández-Barrera et al. 2016); 2) en la revista *International Journal of Climatology* con título “Wheat yield in Spain and associated solar radiation patterns” (Hernández-Barrera &

³Acrónimo del término inglés General Large Area Model.

⁴Acrónimo del término Grupo para la Investigación del Clima y Aplicaciones.

⁵Acrónimo del término inglés Coupled Model Intercomparison Project Phase 5.

Prefacio

Rodríguez-Puebla 2017); 3) “Assessing GLAM-wheat simulation to estimate variability and trend of wheat yield in Spain” (en revisión). Estas publicaciones están recogidas en el Capítulo 5 de esta tesis doctoral, acompañadas de un resumen y conclusiones en castellano.

A lo largo de estos años de investigación, la autora ha realizado una estancia de investigación, de 3 meses, en el centro de investigación “School of Earth and Environment” de la Universidad de Leeds, Reino Unido, bajo la tutela de Prof. Andrew J. Challinor y su grupo de investigación “Climate Impacts group” para el desarrollo y aplicación del modelo GLAM para el trigo en España. Además, ha presentado comunicaciones en diversos congresos de carácter internacional y nacional, recibiendo el premio a la mejor contribución de joven investigador en la asamblea general de la EGU⁶ celebrada en Viena (Austria) en abril del 2016.

⁶Acrónimo del término inglés European Geosciences Union.

Prefacio

CAPÍTULO 1

Estado del conocimiento



1.1. El trigo

En este capítulo se muestra una revisión general del estado de los conocimientos de conceptos básicos que se necesitan para el desarrollo de esta tesis doctoral. Para ello la sección 1.1 describirá el cultivo del trigo, haciendo hincapié en su morfología, las etapas de su desarrollo, así como en las diferentes clasificaciones existentes del trigo. La sección 1.2 introducirá el origen del trigo y su historia hasta llegar a su estado actual. La sección 1.3 trata del trigo en España, su distribución espacial y temporal. La sección 1.4 se centrará en las relaciones existentes entre el clima y el trigo, particularizando el estudio para España, y en la sección 1.5 se introducen los modelos agroclimáticos.

1.1. El trigo

El trigo es un cereal de la familia de las Gramíneas (Cendrero 1938), familia a la que pertenecen otros cereales como el arroz, el maíz, la avena, el sorgo, ... Su nombre científico es del género *Triticum* (Belderok et al. 2000), que proviene del latín y significa “quebrado”, “triturado” o “trillado” y hace referencia a la actividad que debe realizarse para separar el grano de trigo de la cascarilla que lo recubre. Además, este género comprende alrededor de unas 23 especies y subespecies, así como un gran número de variedades (Mac Key 2005).

En la actualidad, el trigo es uno de los alimentos más básicos y necesarios del mundo, junto con el maíz y el arroz. Particularmente en España, la producción de trigo es tan grande como la de las olivas, los cítricos y la uva (FAO 2014). La gran mayoría de la producción de trigo mundial se destina a la alimentación, casi un 75 % de la producción se utiliza para hacer harina de trigo. Además, el grano del trigo se utiliza para producir harina integral, sémola, cerveza y una gran variedad de productos alimenticios (Kent 1983). No obstante, el resto de la producción se reserva para las nuevas siembras. Asimismo, otro de los usos importantes del trigo es el aprovechamiento de la paja para los animales, convirtiéndolo de este modo en un elemento indispensable en la estabilidad de los agro-sistemas.

El trigo se puede cultivar en multitud de lugares, sobre todo en aquellos que tienen un clima subtropical, donde la pluviosidad anual varía entre 375-800 mm, también hay producciones en lugares donde las precipitaciones pueden alcanzar los 2800 mm anuales (Ruiz Camacho 1981). Sin embargo, es conveniente que las precipitaciones sean abundantes en la época del crecimiento del trigo, como

en la primavera, mientras que en las épocas más frías sean menores. En el caso de los cultivos de regadío, el riego se realiza unos días antes de la siembra, una vez se haya preparado el terreno, cuando las plantas empiezan a salir de la tierra y cuando comienza a formarse la caña. Por otro lado, la temperatura óptima para el desarrollo del trigo se sitúa entre 10 y 25°C y es perjudicial si la temperatura es inferior a 3°C o superior a los 33°C (Ruiz Camacho 1981).

1.1.1. Morfología del trigo

El trigo es una planta anual herbácea que suele medir entre 0.7 y 1.2 m de altura, presentando un sistema radicular fasciculado más o menos desarrollado en función de la textura del terreno, la cantidad de lluvia, la época de siembra y la variedad entre otros (Guerrero 1999). La Figura 1.1 muestra las diferentes partes de la planta del trigo, que a continuación se detallan:

◇ Raíz

El trigo posee raíces seminales y raíces principales o coronarias. Las raíces seminales se forman a partir de la semilla durante la germinación. Se considera como un sistema primario de raíces que deja de crecer cuando la planta de trigo posee 3 o 4 hojas, en este momento este sistema de raíces tiende a desaparecer y comienzan a formarse las raíces principales o coronarias. Estas raíces se desarrollan a partir de la corona ubicada en el subnudo, que corresponde con el punto de unión del mesocotilo con el coleoptilo. Estas raíces se encargan del crecimiento de la planta a partir de la cuarta hoja. Las raíces principales son muy numerosas y suelen alcanzar una profundidad de 25 cm, e incluso algunas alcanzan hasta un metro de profundidad bajo condiciones muy favorables.

◇ Coleoptilo

El coleoptilo es una estructura del embrión que emerge desde la semilla hacia la superficie del suelo a través de la elongación del mesocotilo, sólo crece unos pocos centímetros hasta que es perforado por la presión de las hojas subyacentes. En el momento en que el ápice del coleoptilo recibe luz, reanuda su crecimiento, elongando y produciendo la emergencia de la plántula. Inmediatamente después de que el coleoptilo aparece sobre el suelo, da paso a la hoja cotiledonar, que es la primera hoja.

◇ Mesocotilo

El mesocotilo es una estructura tubular, de color blanco y es similar a

1.1. El trigo

un tallo, aparece después de que el coleoptilo emerge de la semilla. La elongación del mesocotilo permite que el coleoptilo salga a la superficie, dejándolo a una distancia entre 1.0 y 2.5 cm de la superficie del suelo. En el otro extremo del mesocotilo se desarrolla un subnudo, a partir del cual las raíces principales empiezan a crecer.

◇ Tallo principal

El tallo principal es de tipo herbáceo y puede alcanzar una altura entre 0.5 y 2.5 m. Es una caña hueca, excepto al nivel de los nudos donde tiene una forma cilíndrica, y termina en una espiga. El número de nudos varía entre 6 y 7, brotando de cada uno una hoja. Una vez que se desarrolla el primer nudo del tallo, se empieza a desarrollar la espiga en el extremo del tallo, es decir, en el apical.

◇ Hojas

Las hojas del trigo se componen básicamente de dos partes: una envoltura que rodea al peciolo, que es la parte que une a la hoja con el tallo, denominada vaina. Y el limbo que generalmente tiene una forma alargada y angosta y además, sigue una dirección horizontal. Las dos primeras hojas aparecen rápidamente una vez emerge el coleoptilo a la superficie. Las siguientes hojas van aumentando su tamaño, siendo las de la parte media y alta de cada tallo, las más anchas y de mayor longitud. Además, el trigo tiene apéndices, denominadas aurículas, que se proyectan como prolongaciones de la lámina. Las aurículas se envuelven alrededor del tallo en el punto donde se encuentran la vaina y el limbo de la hoja. La aurícula es una característica fundamental para diferenciar que tipo de cereal es cuando se encuentran en estado vegetativo. En el caso del trigo, las aurículas son cortas y se entrecruzan ligeramente. Por último, las hojas tienen una lengüeta membranosa y transparente entre la lámina y la porción envainadora de la hoja, que se utiliza para diferenciar las especies de cereales y se denomina ligula (ver Figura 1.2).

◇ Inflorescencia

La inflorescencia es una espiga compuesta por un tallo central de entrenudos cortos, llamado raquis, sobre la cual se distribuyen lateralmente entre 15 y 25 espiguillas. Estas constan de un eje principal del que nacen unos filamentos terminados por brácteas, denominadas glumas, que encierran a las flores hasta que empiezan a madurar. Cada espiguilla presenta nueve flores, de las cuáles sólo dos o tres son fértiles. Además, las

flores están protegidas, aparte de por las glumas, por otras dos brácteas: lemma, que es la más externa y pálea, la más interna. Esta última está rematada por una barba, que es la que le da el aspecto plumoso a la espiga del trigo. Las flores son poco vistosas, no presentan ni pétalos, ni sépalos. Sin embargo, cada flor consta de un ovario del que salen dos estigmas plumosos, y es aquí donde se produce el grano del trigo, debido a la fecundación y maduración del ovulo.




Figura 1.1: Morfología de la planta del trigo a lo largo de las etapas de desarrollo. Figura obtenida de la Pontificia Universidad Católica de Chile¹

1.1.2. Etapas de desarrollo según la escala de Zadoks

El ciclo vegetativo del trigo es un proceso complejo en el que diferentes órganos crecen, se desarrollan y mueren. Estos cambios morfológicos en la planta del trigo, a veces son visibles al ojo humano, como es el caso del crecimiento y desarrollo, pero otras no, como por ejemplo el desarrollo de los tejidos. Además, las diferentes etapas visibles y no visibles se pueden superponer. Por

¹http://www7.uc.cl/sw_educ/cultivos/cereales/trigo.htm

1.1. El trigo

estos motivos, la descripción del desarrollo del cultivo del trigo, ya sean procesos externos o internos, se pueden realizar mediante el uso de diferentes fases o escalas. De esta manera, se tiene una referencia de las diferentes etapas de desarrollo por los que atraviesa el cultivo. La escala más utilizada en el cultivo del trigo, es la escala de Zadoks (Zadoks et al. 1974).

La escala de Zadoks sólo describe los estados morfológicos externos del trigo, por lo que sólo involucran algunos procesos de desarrollo y otros de crecimiento.

Esta escala tiene 10 fases numeradas de 0 a 9, considerando una escala decimal de Z0.0 a Z9.9. De manera que, la escala de Zadoks nos permite tener una idea sobre el estado de desarrollo que se sucede con sólo tener una apreciación de la morfología exterior del trigo. La Tabla 1.1 muestra las diferentes etapas de la escala de Zadoks, incluyendo una breve descripción de las mismas. Una descripción más detallada de las sub-fases se puede encontrar en la página web² Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO; Rawson 2001), producido por el departamento de Agricultura.

Además, la escala de Zadoks es útil para determinar los componentes del rendimiento en las distintas fases, y así ayudar a identificar qué componentes están afectando al cultivo debido a las prácticas del agricultor en un determinado momento (Rawson 2001). Para ello se muestra la Figura 1.2, obtenida de la página web de la FAO³ (Rawson 2001), donde se relacionan las fases de la escala de Zadoks (en rojo) con los dos estados internos observables en el ápice (extremo del tallo): doble arruga y espiguilla terminal (ver el texto vertical). Del mismo modo, se muestra el momento en que se inician, crecen y mueren los componentes del tallo (recuadros verdes) y cuándo se forman los componentes del rendimiento (barras).

²<http://www.fao.org/home/es/>

³Acrónimo del término inglés Food and Agriculture Organization of the United Nations.

Capítulo 1. Estado del conocimiento

Tabla 1.1: Fases de desarrollo del trigo siguiendo la escala decimal de Zadoks. La primera columna muestra la enumeración de cada etapa. La segunda columna indica las etapas de desarrollo, que son descritas en la tercera columna. La cuarta columna indica las sub-fase de cada etapa

Fases de desarrollo del trigo			
Etapa principal	Etapa de desarrollo	Descripción	Sub-fase
0	Germinación		0.0-0.9
1	Producción de hojas del tallo principal (TP)	Es la etapa de las plántulas, es decir, es la etapa de crecimiento de la planta desde la emergencia del coleoptilo hasta que las plantas empiezan a producir brotes secundarios (macollarse)	1.0-1.9
2	Producción de macollos	El macollamiento se inicia cuando las plantas tienen entre 2 y 3 hojas. Comenzando a desplegar sus primeras hojas y además crean su propio sistema de raíces, independizándose de la planta que los originó	2.0-2.9
3	Producción de nudos TP (encañado)	Empieza con la formación del primer nudo visible del TP y de la espiga. Los siguientes nudos empiezan aparecer rápidamente. Los macollos producidos durante el último alargamiento del tallo a menudo mueren	3.0-3.9
4	Vaina engrosada	Se forman 2-3 macollos productivos	4.0-4.9
5	Espigado	La espiga empieza a aparecer a través de la vaina de la hoja bandera u hoja superior	5.0-5.9
6	Antesis	El polen se libera y los granos individuales están siendo fertilizados	6.0-6.9
7	Estado lechoso del grano	El grano comienza a madurar, presentando un contenido acuoso	7.0-7.9
8	Estado pastoso del grano	El grano sigue madurando, pero ya no se desprende líquido	8.0-8.9
9	Madurez	El grano es duro y firme y listo para la cosecha. Las espigas y las hojas comienzan a cercarse	9.0-9.9

1.1. El trigo




Figura 1.2: Etapas de desarrollo del cultivo del trigo según la escala decimal de Zadoks relacionadas con los estados internos del cultivo. Figura obtenida de la FAO⁴

1.1.3. Clasificaciones del trigo

A lo largo de la historia, se han elaborado una gran variedad de clasificaciones para el trigo, siendo muy diferentes entre ellas. Entre todas las clasificaciones, podemos destacar la clasificación según la cosecha, según la textura o la dureza del endospermo, según la fuerza, calidad o color de la semilla. A nivel general, se suele utilizar la clasificación según la textura del endospermo, ya que esta clasificación está relacionada con la forma de fraccionar el trigo durante el proceso de trituración del trigo, conocido como molturación (Kent 1983). Sin embargo, debido al gran número de clasificaciones y centrándonos en los objetivos de esta investigación a continuación, sólo se detallan dos: la clasificación según la cosecha (a) y según la dureza del endospermo (b).

⁴<http://www.fao.org/docrep/006/x8234s/x8234s05.htm>

a) Clasificación según la cosecha

De acuerdo a la época de siembra del trigo se pueden distinguir dos tipos de trigo: el trigo de invierno, también conocido como trigo invernal o trigo de ciclo largo, y el trigo de primavera o trigo primaveral o de ciclo corto.

El trigo de invierno es el trigo que se siembra en otoño y se cosecha en primavera-principios de verano, dependiendo del lugar, por lo que necesita climas suaves. También se suele sembrar en el sur de Europa, en aquellos lugares donde el suelo no se congela excesivamente ya que una helada podría afectar adversamente a las plantas jóvenes. Sin embargo, una capa de nieve las protege y las aísla de las bajas temperaturas del invierno.

El trigo primaveral se siembra en primavera y se recolecta a finales del verano-principio de otoño, dependiendo del lugar, al igual que el trigo de invierno. Este trigo se planta en lugares más fríos tales como Canadá, o las estepas rusas. De tal manera, que la siembra del trigo se realiza en primavera y lo antes posible, para poder recoger las cosechas antes de que empiecen las heladas.

El trigo de invierno al ser cultivado en un clima de temperatura y pluviosidad más constantes, madura más lentamente produciendo cosechas de mayor rendimiento. Al contrario que el trigo de primavera, ya que las características climáticas del lugar donde se siembra se caracterizan por tener los máximos de pluviosidad en primavera y a comienzos del verano, y las máximas temperaturas en verano, lo que favorece a una maduración rápida.

b) Clasificación según la dureza del endospermo

Esta clasificación se basa, básicamente, en la utilidad del trigo, por lo que existen dos clases: el trigo blando y el trigo duro. La “dureza” es una característica relacionada con la forma de fragmentar el endospermo. Además, afecta a la facilidad con la que se desprende el salvado del endospermo. Según Berg (1947), la dureza es una característica que se transmite en los cruzamientos y se hereda siguiendo las leyes de Mendel.

El trigo blando se cultiva, principalmente, en zonas cálidas o templadas. El grano al romperse presenta una diferencia de textura entre el borde, que está más duro, y el centro, que es más harinoso. Por lo tanto, el grano se fractura al azar, de tal manera que unas células se fragmentan y se desprenden del

1.2. El origen del trigo y su historia

endospermo, mientras que otras quedan unidas al salvado. El trigo blando se destina fundamentalmente a la producción de pan en Europa y a la producción de pastas en Estados Unidos y Canadá.

El trigo duro se cultiva en zonas más secas que el trigo blando. El aspecto del interior del grano al romperse es cristalino y uniforme. Cuando el grano se fractura tiende a seguir las líneas que limitan las células, por lo tanto, las células del endospermo se separan con más limpieza que las del trigo blando, y tienden a permanecer intactas. Esta variedad de trigo es la más utilizada en Estados Unidos y Canadá, sin embargo, en Europa es menos utilizada, donde se destina a la producción de pasta.

Para realizar esta investigación se ha trabajado con el trigo de invierno, que en España se siembra entre septiembre y finales de octubre, y se recoge entre mayo y junio, dependiendo de cada región. Asimismo, los rendimientos de trigo utilizados en esta tesis doctoral, consideran tanto el trigo duro como el blando. Refiriéndonos al rendimiento de trigo o productividad como el peso de la producción dividida por la superficie dedicada al cultivo que expresamos en t/ha o en 10^3kg ha^{-1} .

1.2. El origen del trigo y su historia

Los orígenes del trigo se remontan a la revolución del neolítico en el Oriente Próximo, convirtiéndose en uno de los alimentos más básicos para el hombre en el viejo mundo. El cultivo del trigo, probablemente, se inició hace 12.000 años en la antigua Mesopotamia (Feldman & Kislev 2007, Colledge & Conolly 2007), evidencias arqueológicas indican que tiene su origen en las montañas del suroeste de Turquía y desde ahí se distribuyeron hacia el norte y el sur de Mesopotamia (Siria, Jordania, Israel e Irak) alrededor del 10.000 antes de la actualidad (a.a.). Posteriormente, se distribuyó por toda la Cuenca Mediterránea hasta llegar a Italia y España alrededor del año 7000 a.a. (Diamond 1997), la cual ha jugado un papel determinante en la diferenciación de los trigos, en particular del trigo duro (Royo 2008). Y alrededor del año 5000 a.a. llegó a Escandinavia y a las Islas Británicas, donde se utilizaba la paja del trigo para hacer techos desde la edad de bronce hasta el siglo XIX.

El trigo originalmente era silvestre y la obtención de la harina en esa época se conseguía machacando el trigo con una piedra, obteniéndose una especie de papilla. Hace unos 8 milenios, el trigo silvestre sufrió una mutación (o una hibridación), dando lugar a una planta tetraploide con semillas más grandes.

Capítulo 1. Estado del conocimiento

Diversos análisis arqueólogos han encontrado hallazgos de restos carbonizados de trigo almidonero (Kent 1983) y huellas de granos de trigo en barro cocido en Irak, que datan del año 6700 antes de Cristo (a.C.) (Ruiz Camacho 1981).

El trigo es una de las primeras plantas cultivadas por los seres humanos para producir alimentos (Hogan 2013), ya que en su estado salvaje no habría podido tener éxito. Una vez que el trigo se empezó a cultivar, comenzó una revolución agrícola en el denominado creciente fértil. Al mismo tiempo, comenzó la domesticación de las especies salvajes que habitaban en esa región, como es el caso de la oveja y la cabra. Estos progresos permitieron el asentamiento de la población, formándose comunidades humanas más complejas, y además surge la escritura. Por lo que estos acontecimientos ponen fin a la prehistoria y dan comienzo a la historia.

El comienzo de la agricultura y la ganadería exigieron un cuidado continuo, lo que generó que las poblaciones tuvieran conciencia acerca del tiempo y de las estaciones. De esta manera, y gracias al conocimiento de que el grano del trigo se puede almacenar durante varias temporadas, las comunidades se vieron obligadas a guardar provisiones para las épocas en las que las producciones eran más bajas.

Cuando surgió la civilización del antiguo Egipto, se introdujo la semilla del trigo para ser cultivada en el valle del Nilo. Los egipcios entre el 2.000 y 3.000 a.C. descubrieron la fermentación del trigo y fueron los primeros en cocinar panes levados (Grundas 2003). Desde allí, se llevaron las semillas a las civilizaciones griegas y romanas.

Alrededor del año 150 a.C. se formaron los primeros gremios de panaderos en Roma, que se encargaban de abastecer pan a los ciudadanos sin posibilidades económicas, de manera gratuita. Es en esta época donde se diseñan los primeros molinos-hornos con una alta capacidad de producción. El consumo del trigo y de pan durante el Imperio Romano alcanzó una gran importancia, quedando recogido en la Biblia. Sin embargo, hasta el siglo XVII no se presentaron grandes avances en los métodos de cultivo, ni en el procesamiento del trigo, sólo cuando se inventó el molino de viento, que generó una nueva fuente para moler los granos de trigo. A finales del siglo XVIII se desarrollaron algunos mecanismos que mejoraron el proceso de molinería, con lo que aumentó la producción de la harina.

En la edad media (1000-1500), las cosechas mejoraron gracias a la rotación de cultivo. Además, se comenzaron a utilizar molinos hidráulicos y eólicos, situados cerca de los cultivos, por lo que el pan se convirtió en un alimento

1.2. El origen del trigo y su historia

básico. A finales de esta época, el trigo fue introducido en América por los colonizadores españoles, produciéndose una nueva derivación del trigo debido a que durante el trayecto, los granos de trigo se guardaron en bolsas de arroz.

La revolución industrial trajo nuevas tecnologías, aparecieron nuevos métodos de molienda y panificación: la utilización de piedras en la molienda fue sustituida por acero, por lo que la harina producida en estos molinos era más fina. Además, con la invención de la energía eléctrica surgieron los motores eléctricos que incrementaron la productividad, como el uso de sembradoras que sustituyeron la difusión de las semillas. Los desarrollos tecnológicos también permitieron mejorar el rendimiento de la planta y así, el trigo pudo llegar a diversas regiones del planeta como Norteamérica y Oceanía.

Durante el siglo XX, se produjo un incremento considerable en el rendimiento del trigo que se debió a las mejoras de las técnicas de cultivo (Rozelle & Huang 2000) y a la selección genética (Kent 1983). Durante las últimas décadas, el trigo experimentó cambios históricos, a partir de la Revolución Verde que se inició a mediados de 1960. Los cambios más significativos tuvieron lugar en los sectores de cereales mixtos del mundo en desarrollo, como es el caso de China (Baloch 1999). Sin embargo, en Asia occidental, en el norte de África y en las zonas tropicales los rendimientos han sido más pequeños debido a que el ritmo de cambio es más lento que en otros lugares. El rendimiento del trigo pasó de alrededor de 0.7 t/ha en 1950, a unas 2.3 t/ha en 1996 en los países en desarrollo (Baloch 1999). Este gran progreso se debe a las nuevas variedades del trigo, que eran más cortas, con altos rendimientos y maduraban más pronto. Además, esto se complementa con las tecnologías que incluyen nuevos métodos de siembra, la cantidad de semillas, la irrigación, la fertilización, la conservación de humedad y la gestión integrada de plagas (Baloch 1999). En España, el rendimiento de trigo ha aumentado un 45 % en el periodo 1980 a 2014. La evolución del trigo en España se muestra en la Figura 1.3, en la cuál las barras rayadas indican la serie temporal del rendimiento de trigo con tendencia y las barras sombreadas continuas la serie temporal del rendimiento del trigo sin tendencia. La línea negra indica la tendencia lineal.

En la actualidad, el trigo es el cereal más utilizado para hacer alimentos, consumiéndose en más de 60 países. Durante muchos años, el productor mundial del trigo fue la Unión Soviética. Sin embargo, actualmente el productor mundial es China produciendo unos 96 millones de toneladas, seguida por la India, Rusia, Estados Unidos y Francia. Además, en el 2015 la producción de trigo alcanzó su record gracias al incremento de la producción en Estados

Unidos, Rusia y la India (FAO 2016).




Figura 1.3: Serie histórica del rendimiento de trigo para toda España con tendencia (barras rayadas) y sin tendencia (barras en sombreado continuo) para el periodo 1980-2014 y la tendencia lineal (línea negra)

1.3. El trigo en España

La agricultura es un soporte primordial para la economía española. En las últimas décadas ha experimentado importantes transformaciones debido a la entrada en la Unión Europea en 1986 y a la modernización tecnológica. Como consecuencia, la agricultura española ha mejorado su productividad, llegando a ser el primer productor mundial de aceite de oliva y aceituna de mesa (MAGRAMA 2016, FAO 2014), el tercero en el mercado mundial del vino (FAO 2014) y el quinto productor europeo de cereales (MAGRAMA 2016). En la actualidad, las principales producciones agrícolas en España son los olivos, la uva, el trigo y los cítricos.

El trigo se cultiva en casi todas las regiones de España debido a que las condiciones climáticas y topográficas de gran parte de España son óptimas para la agricultura de secano, teniendo menor presencia en las zonas costeras. La distribución espacial de la superficie cultivada de trigo en la España Peninsular se muestra en la Figura 1.4, donde los círculos grises indican la superficie de trigo en cada provincia. La comunidad de Castilla y León, en particular la provincia Burgos, es la principal productora de trigo en España, representando el 46 %, aproximadamente, de la producción total (CEAS 2013). Le siguen las comunidades de Castilla La Mancha, Aragón, Andalucía, y el resto de comu-

1.3. El trigo en España

nidades.

En los últimos años, la superficie cultivada de cereales ha descendido desde el 2005 hasta el 2014, reduciéndose en un 4.4% (MAGRAMA 2016), debido al reglamento 1251/1999 establecido por la Unión Europea que exige la reducción de superficie cultiva para efectuar el pago de subvenciones. Sin embargo, el rendimiento medio del trigo ha mejorado en el último quinquenio, incrementándose en un 7.3% (MAGRAMA 2016). Aunque la causa de este crecimiento no está clara, es probable que esté asociada a mejoras de las técnicas agrícolas (Lobell et al. 2011, Lobell & Tebaldi 2014, Moore & Lobell 2015), así como, al aumento de CO_2 en la atmósfera que puede beneficiar a la producción de trigo por los efectos de fertilización (Gervois et al. 2008).

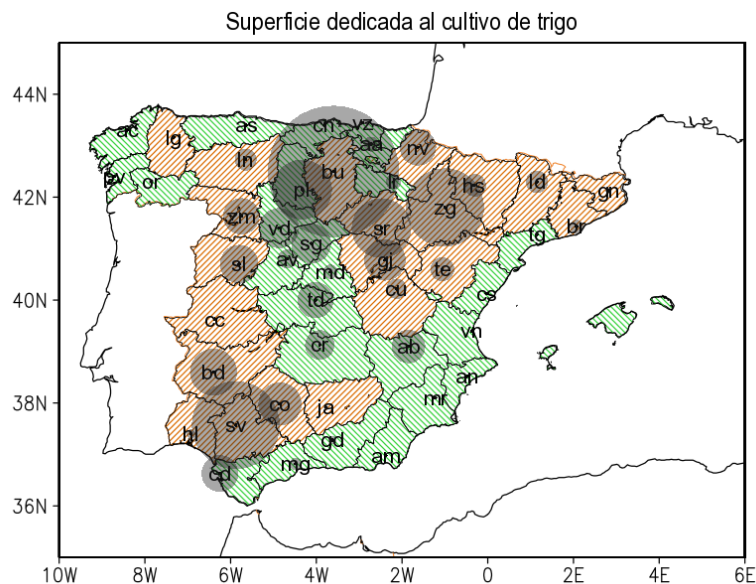


Figura 1.4: Distribución espacial de la superficie cultivada de trigo en la España Peninsular. Los círculos grises indican la superficie cultivada en cada provincia y la simbología el acrónimo de cada provincia

La evolución del rendimiento del trigo en España se muestra en la Figura 1.3 donde, aparte de observar el aumento del rendimiento del trigo, una vez filtrada la tendencia, se puede percibir que los años de mayor (menor) rendimiento son 1988, 1996, 2007 y 2013 (1981, 1995, 2005, 2012). Estos años están relacionados con años húmedos y secos como se indica en Vicente-Serrano et al. (2014). Para demostrar esta influencia en la Figura 1.5 se compara el ciclo anual de precipitación para años de alta productividad de trigo y para los de baja productividad con respecto al ciclo anual de precipitación de todo el

período (1979-2014). Se puede observar como la línea del ciclo para años de alta (baja) productividad queda por encima (debajo). Este es un ejemplo de los efectos de la precipitación ejerce sobre el rendimiento de trigo, lo cuál se analizará con más detalle en los siguientes capítulos.

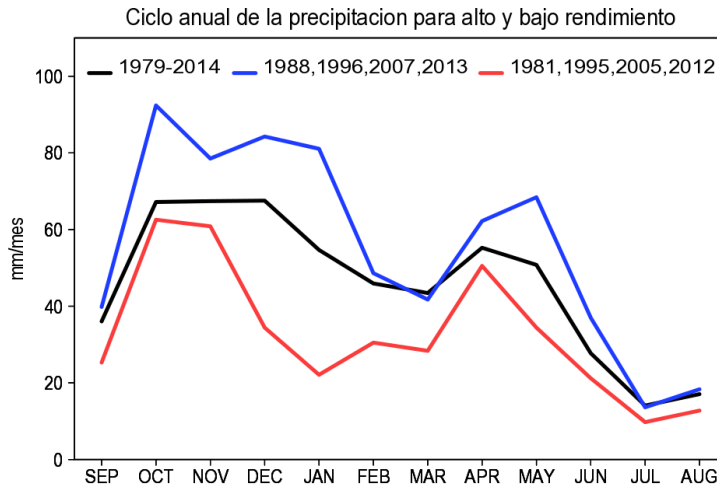


Figura 1.5: Ciclo anual de precipitación para el periodo 1979-2014 (línea negra), para los años de alto rendimiento del trigo (línea azul) y para los años de bajo rendimiento del trigo (línea roja)

1.4. El clima y el trigo

El trigo ha sido el alimento básico de las principales civilizaciones de Europa, Asia occidental y el norte de África durante unos 8000 años (Baloch 1999). El IPCC⁵ (2014), basándose en numerosos estudios que abarcan diferentes regiones y cultivos, informa que los impactos del cambio climático en el rendimiento de los cultivos, comúnmente, son más negativos que positivos. Los estudios que presentan impactos positivos tratan principalmente de regiones de altas latitudes. En el caso particular del trigo, los estudios realizados en Europa muestran un estancamiento del rendimiento en algunos países en las últimas décadas y un impacto negativo debido al cambio climático, a pesar de las mejoras en las tecnologías, ocurriendo lo mismo en el sur de Asia. Además, las proyecciones señalan que el cambio climático sin adaptación tendrá un impacto negativo en las producciones de trigo, arroz y maíz en las regiones tropicales y templadas IPCC (2014).

⁵ Acrónimo del término inglés Intergovernmental Panel on Climate Change.

1.4. El clima y el trigo

Del mismo modo, el Instituto de Estudios Prospectivos Tecnológicos (IPTS⁶) del Centro Común de Investigación (JRC⁷), a través del proyecto “Projection of Economic impacts of climate change in Sectors of the EU based on bottom-up Analysis”, PESETA II, cuyo objetivo es evaluar los impactos del cambio climático en Europa a finales del siglo XXI (2071-2099), informa que las producciones agrícolas en el sur de Europa se reducirán en un 20 % en la década de 2080. Mientras que en el norte de Europa se prevé un aumento en las producciones agrícolas en un 21 % debido a la prolongación del período vegetativo, a la disminución de los efectos del frío en el crecimiento y a la prolongación de períodos sin heladas (Ciscar et al. 2014).

Por estos motivos y a pesar de la mejora continua en la tecnología y en las variedades de los cultivos, el clima es el principal factor que afecta a las producciones agrícolas (Decker 1994). Por lo tanto, es necesario comprender las relaciones existentes entre el clima y el trigo con el fin de paliar los posibles daños y tomar medidas de adaptación ante nuevas situaciones que se puedan presentar como consecuencia del cambio climático.

Existen numerosas variables para caracterizar el clima, pero en este trabajo se van a presentar las características climáticas de aquellas variables que se han encontrado determinantes de la variabilidad de la productividad del trigo, como son la temperatura, la precipitación y la radiación solar, las cuales constituyen la base de los modelos de cultivo.

1.4.1. Clasificación climática en España

España es un país que está dividido territorial y administrativamente en 17 comunidades autónomas y 2 ciudades autónomas, formadas estas, a su vez por 50 provincias, como se muestra en la Figura 1.6. Es un país transcontinental, ya que se encuentra situado tanto en Europa como en el norte de África. En Europa, España ocupa casi toda la Península Ibérica (PI), también conocida como la España Peninsular y el archipiélago de las islas Baleares situadas en el mar Mediterráneo. Y en África se encuentran las ciudades de Ceuta y Melilla, y las islas Canarias, situadas en el océano Atlántico. No obstante, la zona de estudio en esta investigación se va a reducir a la España Peninsular, que se encuentra situada aproximadamente entre los paralelos 35-45°N, y entre los meridianos 10°W-5°E.

La observación de la distribución espacial y la evolución temporal de la

⁶Siglas del término inglés Institute for Prospective Technological Studies.

⁷Siglas del término inglés Joint Research Centre.

Capítulo 1. Estado del conocimiento

producción de trigo, nos hace cuestionar si está relacionada con los diferentes climas de España y con la variabilidad climática. La Península Ibérica se encuentra situada en una zona de transición entre latitudes templadas y tropicales, con cuatro estaciones delimitadas por los solsticios de invierno y verano, y los equinoccios de primavera y otoño. La gran complejidad orográfica de la Península Ibérica, así como su situación geográfica hace que el país presente una gran variabilidad climática espacial y temporal (Font Tullot 2000), existiendo desde ambientes semidesérticos y mediterráneos hasta zonas que presentan un clima atlántico y de alta montaña. La Figura 1.7 muestra una clasificación de los distintos tipos de clima de la PI⁸ delimitados por la clasificación de Köppen (Köppen 1884, Kottek et al. 2006) para el periodo 1981-2010.



Figura 1.6: División territorial de España por provincias⁹

⁸ Acrónimo del término español Península Ibérica.

⁹ Figura obtenida de <http://www.mecd.gob.es/ministerio-mecd/organizacion.html>

1.4. El clima y el trigo

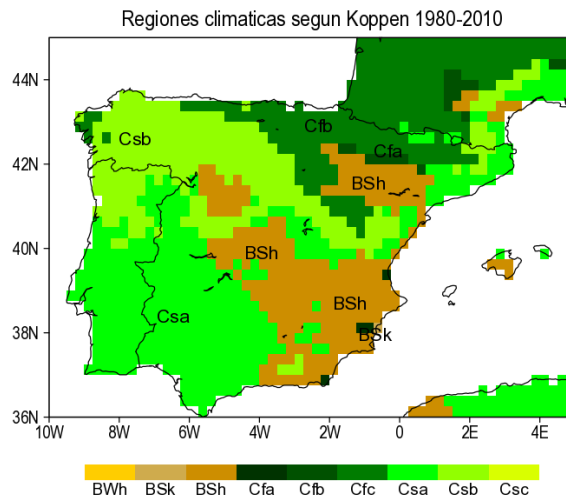


Figura 1.7: Clasificación del clima en la PI, según la clasificación de Köppen. La zona BSh corresponde con un clima de estepa caliente, la zona BSk es un clima de estepa frío, la zona BWh indica un clima desértico frío, la zona Cfa corresponde con un clima mediterráneo húmedo con veranos cálidos, la zona Cfb presenta un clima mediterráneo húmedo con verano templados, Cfc indica un clima Mediterráneo húmedo con verano frío, la zona Csa corresponde con un clima mediterráneo con verano seco y caliente y la zona Csb presenta un clima mediterráneo con verano seco y templado. Figura obtenida utilizando el programa de Manzanas Rodrigo y datos E-OBS¹⁰

Otros autores nos muestran clasificaciones climáticas más particularizadas (Linés 1970, Font Tullot 2000, Capel Molina 2000, Martín Vide & Olcina 2001). De entre todas las clasificaciones existentes, en la Tabla 1.2 se muestra la clasificación climática de España según Martín Vide & Olcina (2001).

La temperatura a lo largo del siglo XX aumentó progresivamente, siendo este aumento más marcado a partir de 1975, incrementando unos $0.5^{\circ}\text{C}/\text{década}$. Este aumento ha sido más pronunciado en primavera y verano en los últimos 30 años del siglo XX. Por el contrario, las precipitaciones en las tres últimas décadas del siglo XX disminuyeron significativamente con respecto a las décadas de los 60 y los 70, registrándose los valores más bajos de precipitación desde 1950. No obstante, no se puede afirmar que la precipitación haya descendido de forma generalizada (CLIVAR 2010) debido a la ausencia de datos de principios del siglo XX y a la fuerte variabilidad interanual, asimismo dependiendo de los periodos y épocas, se obtienen tendencias negativas y positivas. Por otro lado, la radiación solar en la PI ha aumentado desde 1980, incrementando $3.9\text{ Wm}^{-2}/\text{década}$. Este aumento es más pronunciado en la estación de verano ($6.5\text{ Wm}^{-2}/\text{década}$) (Sánchez-Lorenzo et al. 2013).

¹⁰Meteorology Group. Instituto de Física de Cantabria (CSIC-UC).

Capítulo 1. Estado del conocimiento

Tabla 1.2: Regionalización climática de España. La primera columna indica los tipos de clima. La segunda columna muestra los subtipos de cada clima, y la tercera las variedades de cada subtipo. La cuarta y quinta columna muestran la precipitación media anual (mm) y el régimen pluviométrico estacional, respectivamente. La sexta y séptima columna muestran la temperatura median anual (°C) y amplitud térmica media anual (°C), respectivamente. Y la octava columna indica otras características importantes. Tabla obtenida de Martín Vide & Oleina (2001)

Tipo de clima	Subtipo	Variedad	P (mm)	Régimen pluviométrico estacional	T (°C)	ΔT (°C)	Otras características
OCEÁNICO	Atlántico	Gallego	1000 – 2500	Máximo invernial y mínimo invernial	11 – 15	8,5 – 12	Abundante nubosidad y elevada humedad ambiental
		Asturiano y cántabro	900 – 1500		12 – 14	10 – 11	
		Vasco litoral	1100 – 2000		12 – 14	10 – 12	
	De montaña	-	1000 – 2500	-	< 12	-	
MEDITERRÁNEO	Submedit.	-	700 – 900	-	11 – 14	14,5 – 16	-
	Continental	Meseta Norte	350 – 550	Máximo invernial (primav) y mínimo estival	10 – 12,5	16 – 18	Heladas frecuentes en invierno
		Meseta Sur	350 – 550		12 – 15	18 – 20,5	Temperaturas máximas estivales muy altas
		Valle del Ebro	300 – 550	Máximos equinociales	13 – 15	18 – 20	Viento NW seco

1.4. El clima y el trigo

Tipo de clima	Subtipo	Variedad	P (mm)	Régimen pluviométrico estacional	T (°C)	ΔT (°C)	Otras características	
MEDITERRÁNEO	De Fachada Oriental	Catalán	550 – 750	Máximo otoñal y mínimo estival	14 – 17	14 – 17	Precipit. torrenciales de otoño	
		Valenciano	400 – 850		15,5 – 17,5	13,5 – 16,5		
		Balear	400 – 800		16 – 18	13,5 – 15,5		
	Meridional	Litoral	-	400 – 750	Máximo invernal y mínimo estival	17 – 18,5	10 – 13,5	Excepción de heladas
		Valle del Guadaquivir	-	550 – 650		17 – 18,5	15 – 18,5	Temperaturas máximas estivales muy altas
		Extremeño	-	450 – 600		16 – 16,5	16,5 – 18	Temperaturas máximas estivales altas
	Árido o del Sureste	-	150 – 350	Mínimo estival	14,5 – 18,5	13,5 – 17,5	Extrema aridez	
	De Montaña	-	600 – 2000	-	< 14	-	-	
SUBT. /TROPICAL	Litoral	-	75 – 350	Máximo invernal y mínimo estival	18 – 21	5 – 7,5	Alisios en el norte y extrema aridez en el sur	
	De mar de nubes	-	500 – 1000		13 – 16	6 – 8	Elevada humedad ambiental	
	De altura	-	450 – 700		< 12	12 – 14	Aire muy seco	

El 2016, ha sido el sexto año más cálido en España desde 1965, y el quinto año más cálido de lo que llevamos siglo XXI con una temperatura media de 15.8°C, incrementándose la temperatura en casi 1°C (AEMet 2017). Con respecto a las precipitaciones, el 2016 ha sido un año húmedo en el conjunto de España donde la precipitación media rondó los 685 mm, es decir, un 5% más que su valor normal (AEMet 2017). Este aumento de precipitación se debe principalmente a que en los meses de invierno y primavera el acumulado de precipitación aumentó en un 40%, con respecto a su valor normal (AEMet 2017).

1.4.2. El trigo y la temperatura

La temperatura es un factor muy importante para el crecimiento y desarrollo del cultivo, así como para su rendimiento. Tanto las temperaturas extremas como el cambio brusco de temperaturas en el día, el cual se cuantifica por el rango diurno de temperatura (DTR¹¹), pueden tener impactos significativos en los rendimientos de los cultivos. Además, la temperatura está relacionada con la precipitación y la radiación solar, dependiendo de si es temperatura máxima o mínima; a mayor radiación, la temperatura máxima aumenta, pero la mínima disminuye, y con un aumento de precipitación, la temperatura máxima disminuye y la temperatura mínima suele aumentar. El trigo es un cultivo apto en un ambiente fresco, por lo que el crecimiento y el desarrollo del trigo es vulnerable a las altas temperaturas (Li 2008). No obstante, el fenómeno que más perjudica al trigo es el cambio brusco de temperaturas, sobre todo en la época de floración (Escobar 1972), que en nuestro caso se da en primavera. Lo que implica problemas en la fecundación de las flores, provocando la presencia de espigas vanas y una disminución de los rendimientos. Además, existen estudios que muestran que el DTR es un buen indicador del impacto del cambio climático en el trigo, ya que puede caracterizar a las heladas y el riesgo de calor, encontrando además relaciones opuestas entre el DTR y los cultivos (Hernández-Barrera et al. 2016, Chen et al. 2015, Lobell 2007, Nicholls 1997). Sin embargo, otros indican que, en latitudes altas, un aumento de las temperaturas puede prolongar el ciclo vegetativo del trigo y reducir el riesgo de las heladas (Trnka et al. 2011).

La variabilidad espacial de la temperatura queda recogida en la Figura 1.8,

¹¹Acrónimo del término inglés Diurnal Temperature Range.

1.4. El clima y el trigo

la cual muestra la distribución espacial de la temperatura media (T_{mean}), máxima (T_{max}), mínima (T_{min}) y el DTR en la PI para el promedio anual del periodo en el que se lleva a cabo este estudio (1979-2014). La temperatura promedio anual (Figura 1.8a) indica un gradiente de aumento de norte a sur y disminución desde la costa hacia el interior. Las temperaturas más altas se obtienen en las cuencas de los ríos, por ejemplo la temperatura máxima promedio anual en la cuenca del Guadalquivir es superior a los 22°C (Figura 1.8b). Por otra parte, las temperaturas más bajas se observan en los sistemas montañosos, por ejemplo en los Pirineos donde las temperaturas mínimas promedio anual (Figura 1.8c) varían entre 2 y 6°C. El contraste térmico tan amplio también se refleja en el DTR, con valores más bajos en las zonas costeras que en el interior (Figura 1.8d). La variable derivada DTR refleja el grado de continentalidad. De modo que, los valores mayores para DTR (Figura 1.8d) se obtienen en el sistema Ibérico, Andalucía occidental, en Castilla y León y en Castilla La Mancha, y los más bajos en las regiones costeras y en las zonas de los Pirineos.

En esta investigación hemos obtenido relaciones significativas entre el trigo y la temperatura mínima en invierno, la máxima de primavera y el DTR de invierno. Por ello mostramos en las Figuras 1.9, 1.10 y 1.11 las series temporales de estas variables, promediadas para la España peninsular, en el periodo de estudio considerado en este trabajo, donde se puede observar que tanto la temperatura mínima, como la temperatura máxima han aumentado. Destacamos el aumento de temperatura máxima y mínima en primavera.

Los procesos de vernalización y fotosíntesis están relacionados con las altas y bajas temperaturas (Duncan & Hesketh 1968, Vong & Murata 1979, Hay & Porter 2006). Numerosos estudios de diversas partes del mundo muestran que el calentamiento global produce un impacto negativo en los cultivos (Lobell & Asner 2003, Peng et al. 2004, Tao et al. 2006, entre otros). Sin embargo, otros estudios indican que el calentamiento puede causar impactos positivos, como es el caso de Chmielewsk et al. (2004) que observó que el aumento de temperatura favorecía al desarrollo del cultivo en Alemania. Por lo tanto, el impacto de la temperatura en los rendimientos del cultivo depende de la latitud de la región donde se encuentre el cultivo (Villegas et al. 2016).

Capítulo 1. Estado del conocimiento

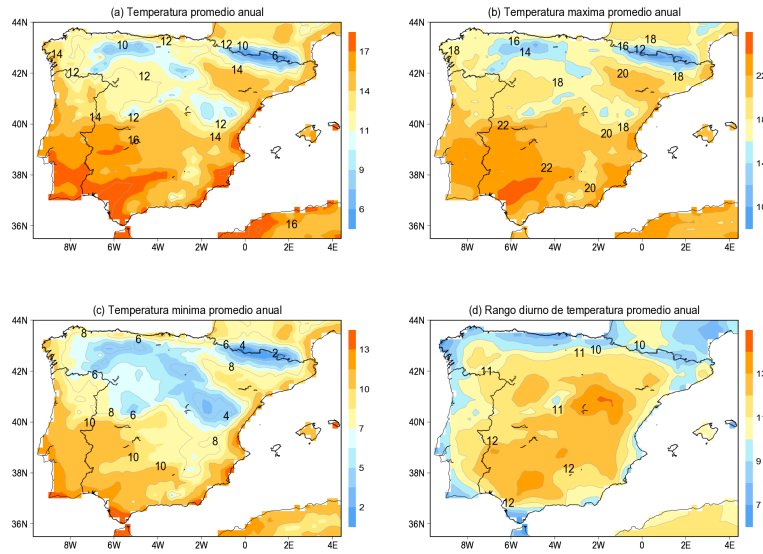


Figura 1.8: Distribución espacial de la temperatura media (a), máxima (b) y mínima (c) y rango diario de temperatura (d) en la Península Ibérica para el periodo 1979–2014

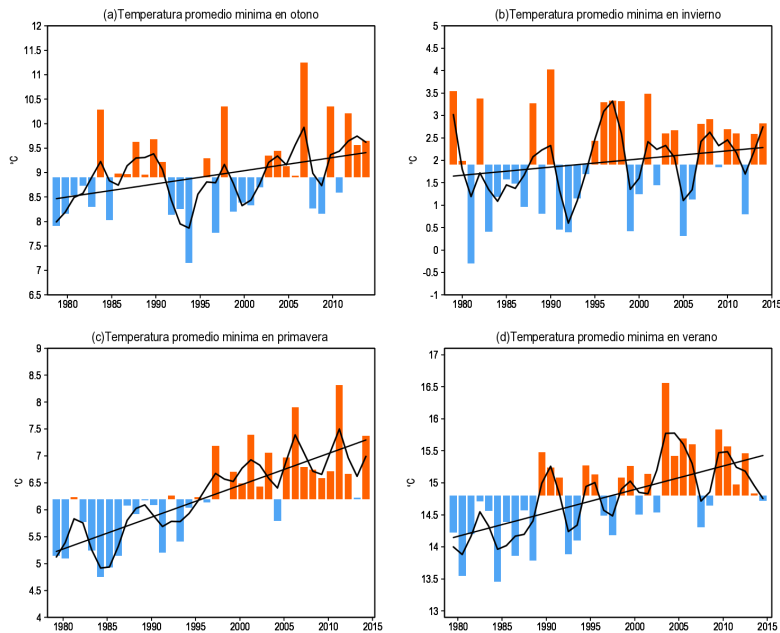


Figura 1.9: Series temporales de la temperatura mínima de otoño (a), invierno (b), primavera (c) y verano (d) en la España peninsular para el periodo 1979–2014

1.4. El clima y el trigo

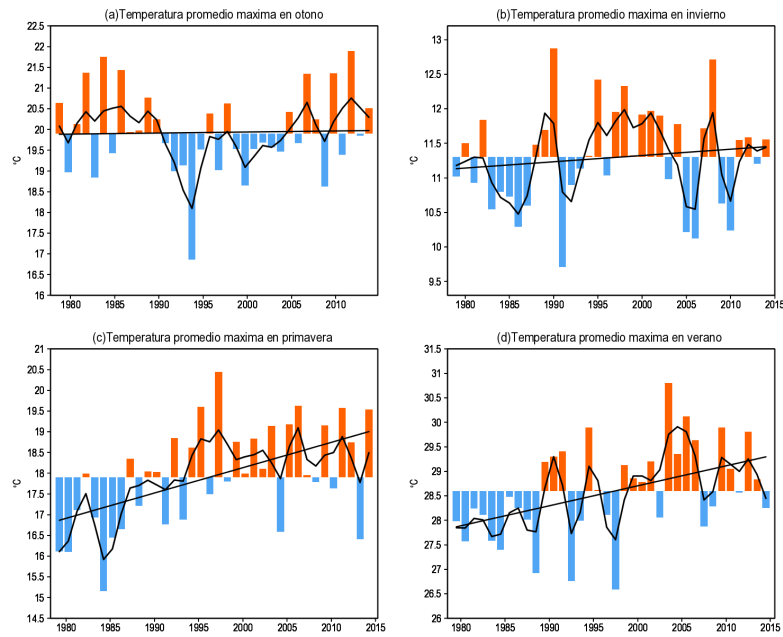


Figura 1.10: Series temporales de la temperatura máxima de otoño (a), invierno (b), primavera (c) y verano (d) en la España peninsular para el periodo 1979–2014

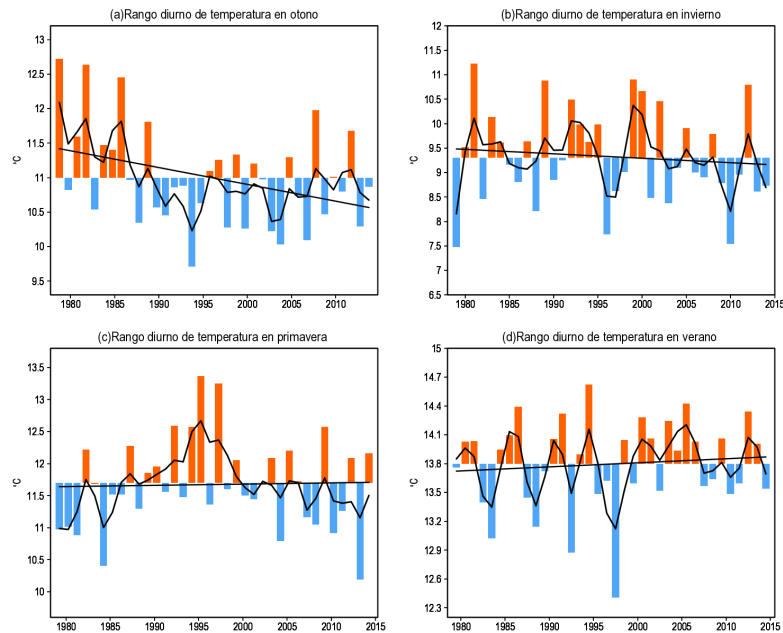


Figura 1.11: Series temporales del rango diurno de temperatura de otoño (a), invierno (b), primavera (c) y verano (d) en la España peninsular para el periodo 1979–2014

1.4.3. El trigo y la precipitación

En condiciones de sequía, disminuye la tasa de fotosíntesis en la planta, provocando una reducción de la biomasa, se reduce la transpiración del cultivo y la respiración disminuye debido al cierre de las estomas. Por otro lado, el estrés hídrico depende de las propiedades hidrológicas del suelo, del nivel de evaporación del suelo y de la transpiración de las plantas, pudiendo provocar, junto con un aumento de la temperatura, una gran reducción del rendimiento del cultivo. Por lo tanto, la agricultura de secano está limitada por la disponibilidad de agua (Gamo 1999). En el caso del cultivo del trigo, el crecimiento de las hojas se ve reducido cuando el nivel de agua en el suelo se encuentra por debajo del 50 % (Meyer & Green 1980, 1981). Diversos estudios han analizado los efectos del déficit hídrico del suelo durante el ciclo vegetativo del trigo (Fischer 1980, García et al. 2003, Shpiler & Blum 1991, Van Herwaarden et al. 1998), obteniendo diferentes respuestas del rendimiento del trigo al estrés hídrico debido a las diferentes resistencias a la sequía que presentan las variedades de trigo, y según las condiciones ambientales del lugar, como pueden ser la temperatura o los estados de los nutrientes.

El trigo al ser un cultivo de invierno, necesita una cantidad de humedad distribuida convenientemente durante todo el ciclo vegetativo para obtener rendimientos mejores, siempre y cuando los otros factores climáticos sean óptimos para la planta (Escobar 1972). Diferentes estudios han encontrado que la precipitación produce efectos positivos en el rendimiento del trigo (Challinor et al. 2014, Luo & Wen 2015). Sin embargo, otros estudios han encontrado que un exceso de precipitación puede afectar negativamente al trigo (Rotter et al. 2013), incluso que las sequías del verano pueden ser positivas para el trigo, dependiendo del lugar (Brown 2013). Estos estudios indican que el rendimiento del trigo no sólo se ve afectado por la cantidad de precipitación, sino también por la distribución de la precipitación. Un exceso de precipitación y una deficiente distribución de las lluvias durante el ciclo del trigo puede producir empozamientos del terreno, lo que con lleva a una reducción significativa del rendimiento del trigo.

Por otro lado, el rendimiento depende de la humedad del suelo y esta se ve afectada no sólo por la precipitación, sino por la evapotranspiración. De manera que, numerosos estudios han encontrado relaciones entre el rendimiento del trigo y la evapotranspiración (Mogenson et al. 1985, Steiner et al. 1985,

1.4. El clima y el trigo

Musick et al. 1994, Zhang & Oweis 1999, Zhang et al. 1999, Changnon & Hollinger 2003). Además, otros estudios han analizado la influencia del balance de agua, que es representada por diversos índices, como es el caso del Índice de Precipitación-Evapotranspiración Estandarizado, entre otros (Vicente-Serrano et al. 2012, Páscoa et al. 2016).

La precipitación es el elemento climático de gran interés en la PI debido a la escasa cantidad que cae en gran parte del territorio y su gran variabilidad espacial y temporal (Castro et al. 2005). La precipitación media anual disminuye en la PI de norte a sur y de oeste a este, como se muestra en la Figura 1.12. En dicha figura, se muestra la distribución promedio anual de la precipitación en la PI para el periodo 1979-2014. Atendiendo al régimen de precipitación acumulada anualmente se puede realizar la siguiente clasificación: zona lluviosa con precipitación superior a 600 mm, zona seca con precipitación entre 600 y 350 mm y zona semiárida con precipitación inferior a 350 mm. Aunque la distribución geográfica de la precipitación media anual es compleja, se puede considerar que las zonas lluviosas se encuentran en el norte, noroeste y las zonas montañosas de la PI, donde las precipitaciones medias anuales rondan los 1000 mm. Las zonas secas abarcan principalmente la zona central de la PI, la cuenca del

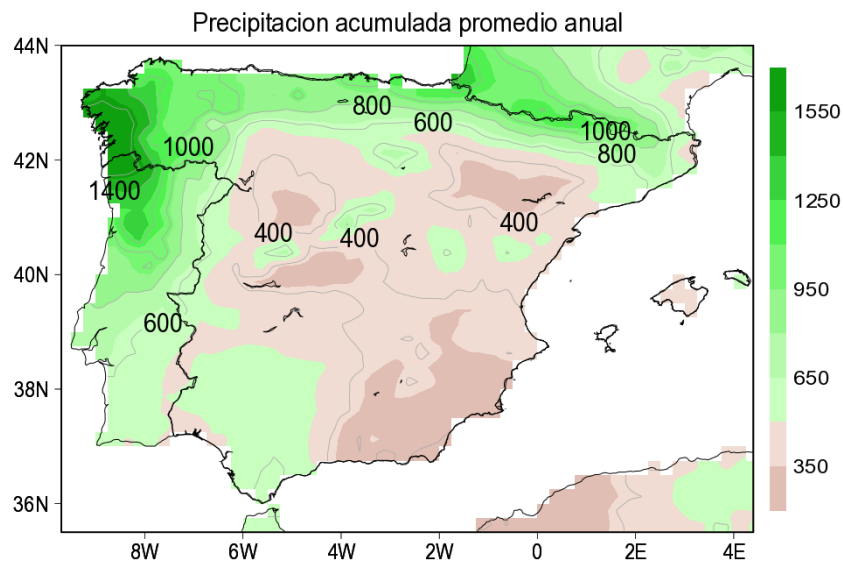


Figura 1.12: Distribución espacial de la precipitación anual en la Península Ibérica para el periodo 1979–2014

Ebro y la del Guadalquivir, y la costa oriental, excluyendo las costas sur del Mediterráneo que corresponde con una zona semiárida.

En la Península Ibérica las precipitaciones son muy escasas en verano y se distribuyen de forma irregular a lo largo del año, como lo muestran los climogramas de la Figura 1.13. Por ejemplo, en Almería, con un clima desértico, el máximo de pluviosidad se alcanza en noviembre y está en torno de los 30 mm/mes. Sin embargo, en La Coruña y Sevilla el máximo de pluviosidad se alcanza en diciembre. En Salamanca la precipitación más abundante se produce en otoño y en Zaragoza en primavera.

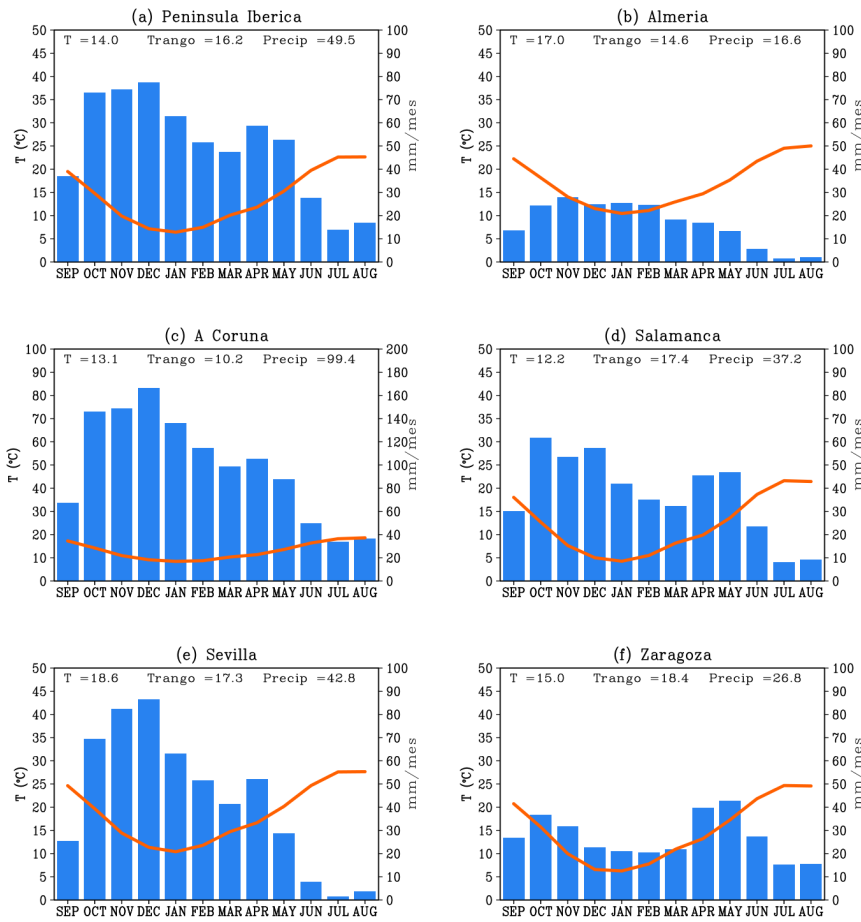


Figura 1.13: Climogramas para el periodo 1979-2014 en la Península Ibérica (a), Almería (b), La Coruña (c), Salamanca (d), Sevilla (e) y Zaragoza (f). Las barras azules representan las precipitaciones mensuales medias y la línea roja indica la temperatura media mensual.

Los números superiores indican la temperatura media (T), la diferencia entre la temperatura más alta y la más baja (T_{rango}) y la precipitación acumulada (Precip)

1.4. El clima y el trigo

Presentamos en la Figura 1.14 la evolución de la precipitación, promediada para la España peninsular, para las estaciones durante el periodo objeto de estudio. Observándose que en promedio se produce un ligero aumento de precipitación en otoño y primavera, sin embargo, disminuye en invierno y verano. En este estudio hemos obtenido relaciones entre la productividad de trigo y el índice de precipitación estandarizado (SPI¹²) de otoño y primavera, cuyo cálculo de específica en el Capítulo 3.

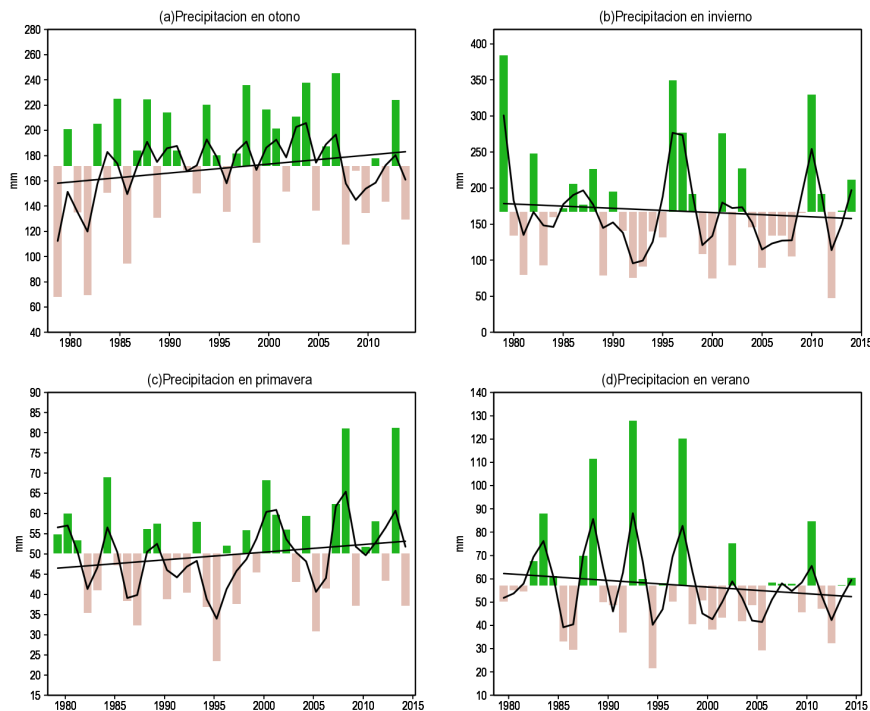


Figura 1.14: Series temporales de la precipitación acumulada de otoño (a), invierno (b), primavera (c) y verano (d) en la España peninsular para el periodo 1979–2014

1.4.4. El trigo y la radiación solar

La radiación solar afecta al crecimiento de la planta, principalmente en la biomasa, ya que es necesaria para convertir el dióxido de carbono y el agua en carbohidratos y oxígeno. Por lo que, una reducción de la radiación solar provoca una disminución en las tasas de la fotosíntesis. El trigo necesita aproximadamente unas 1500 horas de sol para completar su ciclo (Escobar 1972).

¹² Acrónimo del término inglés Standardized Precipitation Index.

Un déficit de horas provocaría que la planta alargara su ciclo vegetativo, permaneciendo en estado de hierba sin alcanzar la floración, o en el caso de que llegue a florecer la polinización sería deficiente, lo que provoca un vaneamiento en las espigas. Además, la ausencia de radiación solar en el trigo provoca más enfermedades, los rendimientos son más deficientes y la calidad del grano es baja (Escobar 1972). Por estas razones, la radiación solar es un factor necesario e imprescindible a lo largo del todo ciclo vegetativo del trigo.

Sin embargo, la radiación solar está estrechamente relacionada con la precipitación debido a que las nubes provocan una reducción de la radiación solar, y a su vez pueden producir precipitaciones (Nicklin 2013). En otras palabras, la radiación solar y la precipitación están inversamente relacionadas ya que a mayor duración de las precipitaciones corresponden menos horas de sol (Escobar 1972). De modo que, estos efectos opuestos evidencian la dificultad de analizar el efecto de la radiación, que además dependerá de la escala temporal. No obstante, son escasos los estudios empíricos realizados que tienen como objetivo analizar las relaciones entre la radiación solar observada y las producciones agrícolas. Por ejemplo, algunos estudios compararon la sensibilidad de los modelos basados en procesos a la radiación solar (Trnka et al. 2007). Otros analizaron los efectos de la radiación solar en el trigo de invierno y el maíz (Ceglár et al. 2016). Recientemente, Leng et al. (2016) obtuvieron la contribución de la radiación solar en el maíz y la soja, y a su vez obtuvieron las relaciones que existe en la radiación solar, la temperatura y la precipitación. Asimismo, Hernández-Barrera & Rodríguez-Puebla (2017) determinaron las relaciones entre el rendimiento de trigo en España y la radiación solar.

La radiación solar en superficie, al igual que la precipitación y la temperatura, presenta una variabilidad espacial en la PI aumenta desde el norte al sur como se observa en la Figura 1.15 y varía con los meses registrándose los valores más bajo durante los meses de noviembre, diciembre y enero (Figura 1.16). Las zonas semiáridas y las zonas secas, tales como Almería y Sevilla, registran los máximos de radiación solar de la PI durante todo el año. Por otro lado, en la meseta norte la radiación solar varía entre 70 Wm^{-2} y 310 Wm^{-2} , registrándose valores más altos en Salamanca, y más bajos en Burgos. Y en las zonas lluviosas, como Vizcaya, se registran los mínimos de radiación solar.

En esta investigación hemos obtenido la influencia de la radiación solar en superficie en la productividad de trigo a lo largo de las estaciones de otoño, invierno y primavera. En la Figura 1.17 se muestra la evolución de la radiación solar, promediada para la España peninsular, para las diferentes estaciones.

1.4. El clima y el trigo

Cabe destacar la tendencia creciente en verano, lo cuál se asocia con el aumento de la temperatura máxima y la disminución de la precipitación.

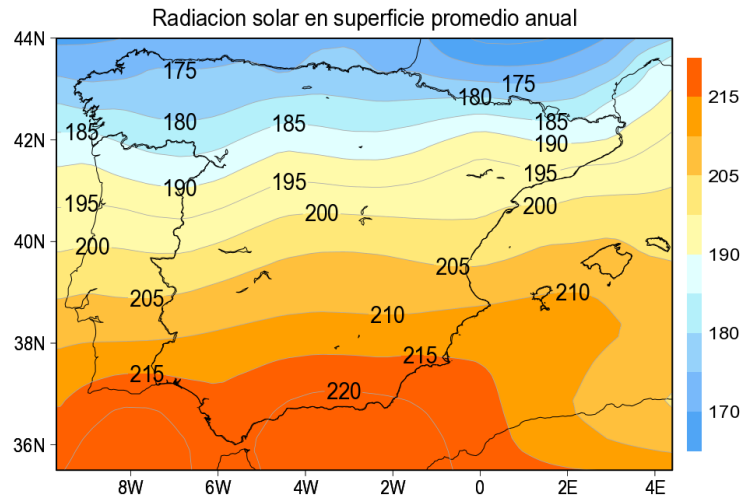


Figura 1.15: Distribución espacial de la radiación solar anual en la Península Ibérica para el periodo 1979-2014




Figura 1.16: Ciclo anual de la radiación solar en superficie para diversos lugares de la Península Ibérica

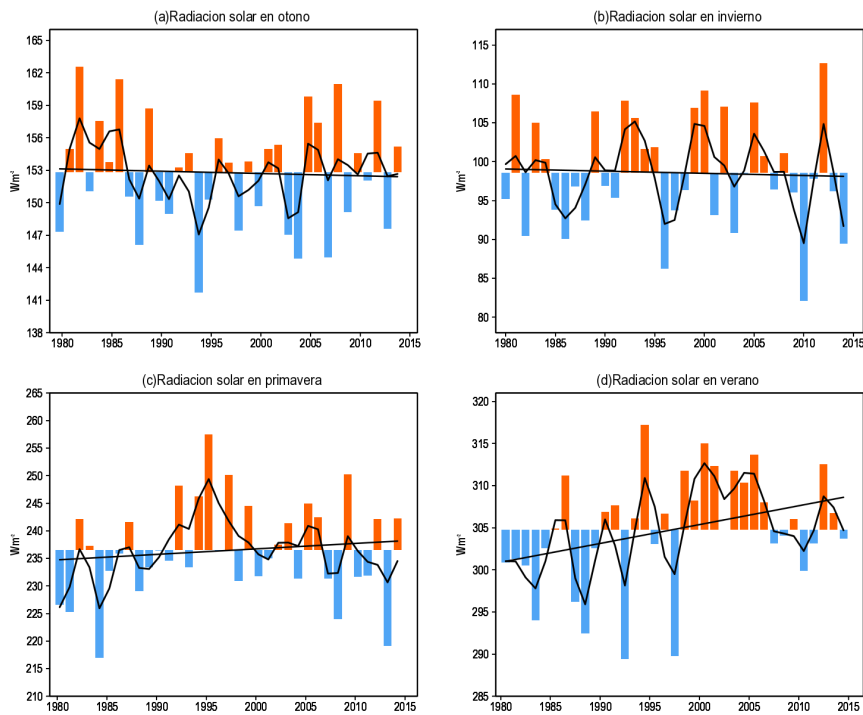


Figura 1.17: Series temporales de la radiación solar de otoño (a), de invierno (b), de primavera (c) y de verano (d) en la España peninsular para el periodo 1979–2014

1.5. Modelos agroclimáticos

Los modelos agroclimáticos son ecuaciones que tratan de representar los efectos del clima en las producciones agrícolas. Por una parte, se agrupan los modelos que consideran la dinámica del cultivo bajo la denominación de basados en procesos. Estos modelos empiezan a desarrollarse en la década de 1960 (White et al. 2011). Por otra parte, la disponibilidad de datos favorece al desarrollo de modelos que se elaboran a partir de las relaciones estadísticas o empíricas entre las observaciones de las producciones agrícolas y los datos meteorológicos (Auffhammer & Schlenker 2014). Estos modelos son conocidos como modelos empíricos o estadísticos. Lobell & Asseng (2017) indican que esta clasificación es imperfecta ya que los modelos basados en procesos incluyen parámetros que se derivan de datos experimentales o calibraciones con observaciones. Y los modelos estadísticos incluyen implícitamente los efectos del clima en los procesos fisiológicos del crecimiento del cultivo. Además, la comparación de predicciones entre ambos tipo de modelos es limitada porque

1.5. Modelos agroclimáticos

los modelos basados en procesos suelen incorporar los efectos de CO_2 , mientras que los estadísticos no lo consideran. Por ello, Lobell & Asseng (2017) recomiendan, para estudios de impactos, complementar las proyecciones derivadas con modelos estadísticos y basados en procesos.

1.5.1. Modelos empíricos

Los modelos empíricos se utilizan para analizar las relaciones estadísticas observadas entre los factores ambientales y el rendimiento del cultivo, y no en los mecanismos causales del comportamiento de un sistema. En la actualidad son numerosos y muy variados los estudios en los que se obtienen modelos estadísticos relacionados con la agricultura, por ejemplo, podemos destacar los modelos de Hernández-Barrera et al. (2016, 2017), Hawkins et al. (2013), Lobell & Burke (2010), Lobell et al. (2011), Bergamaschi et al. (2007), Davidian & Giltinan (1995), Pinheiro & Bates (2000), entre otros. Además, los modelos estadísticos han sido utilizados recientemente para el meta-análisis sobre el efecto del cambio climático en los rendimientos de los cultivos (Wilcox & Makowski 2014, Challinor et al. 2014) y para desarrollar meta-modelos, es decir, para desarrollar modelos estadísticos que resumen los modelos basados en procesos (Makowski 2015).

El número de datos de entrada necesarios para el funcionamiento de los modelos estadísticos es bajo. Habitualmente, estos modelos utilizan datos climáticos estacionales o mensuales, de modo que los modelos pueden ser desarrollados para usarse en cualquier escala espacial (Lobell 2013). El uso de datos climáticos promediados puede conducir a errores a la hora de predecir el rendimiento ya que los cultivos pueden responder de forma no-lineal a las condiciones climáticas (Hansen et al. 2006). Asimismo, estos modelos dependen en gran medida de la calidad y la disponibilidad de los datos históricos, por lo que pueden que no sean válidos fuera del lugar y del clima para el que fueron diseñados (Challinor et al. 2004).

1.5.2. Modelos basados en procesos

Los modelos basados en procesos, se caracterizan por establecer las relaciones causa-efecto y realizar una descripción cuantitativa de los mecanismos y procesos que afectan a un sistema (López et al. 2011), simulando el crecimiento del cultivo, el rendimiento y su respuesta al medio ambiente a un nivel de campo. No obstante, queremos destacar el modelo agrícola “The general large-area

model (GLAM) for annual crops” ya que ha sido utilizado en esta investigación. GLAM ha sido diseñado para evaluar los impactos de la variabilidad climática y el cambio en los cultivos.

El objetivo de GLAM es combinar los efectos de los modelos agrícolas basados en procesos a pequeña escala con los beneficios de los modelos empíricos, para poder así analizar la respuesta de los cultivos al clima y simular su rendimiento a escalas espaciales, comparables a la resolución de los modelos climáticos, y evitar cualquier complejidad asociada a los procesos que simulan a un nivel más detallado (Challinor et al. 2004). Además, GLAM utiliza un único parámetro, Yield Gap Parameter (YGP) para tener en cuenta los factores como los nutrientes, plagas, enfermedades, entre otros. De esta manera, GLAM no requiere de una calibración local extensa como otros modelos agrícolas, y se puede centrar en la respuesta del rendimiento del cultivo a la variabilidad climática. La descripción específica de este modelo, se explicará en detalle en el Capítulo 4.

Según Van Ittersum & Donatelli (2003), los modelos basados en procesos más destacados son los modelos de Wageningen (de Wit 1958), Decision Support System for Agrotechnology Transfer (DSSAT; Jones et al. 2003), Cropping Systems Simulation Model (CropSyst; Stöckle et al. 2003), Agricultural Production Systems Simulator model (APSIM; Keating et al. 2003) y Standard multidisciplinary Simulator for Crops (STICS; Brisson et al. 2003). Cada uno de esos modelos han sido diseñados para diversas aplicaciones, presentando ciertas ventajas y algunas limitaciones a su vez, debido a la capacidad de adaptación que tienen para simular el crecimiento y el desarrollo de los cultivos y su respuesta a las variables ambientales. Por ejemplo, el modelo agrícola Sirius-Quality (Jamieson et al. 1998), que fue desarrollado en el Instituto Nacional de Investigación Agrónoma en Francia (INRA) para simular la fenología y el crecimiento del trigo de primavera e invierno, aunque también simula el crecimiento de cereales de grano pequeño, incluyendo la cebada, la avena, el arroz y el triticale.

Los modelos desarrollados en Wageningen son eficaces para simular la producción potencial bajo condiciones climáticas medias (Van Ittersum et al. 2003), no obstante, presentan algunas limitaciones importantes a la hora de simular el sistema de los cultivos y las dinámicas del agua del suelo, los nutrientes y la materia orgánica del suelo (Van Ittersum et al. 2003). Sin embargo, DSSAT¹³ que surgió de la “International Benchmark Sites Network for Agro-

¹³Acrónimo del término inglés Decision Support System for Agrotechnology Transfer.

1.5. Modelos agroclimáticos

technological Transfer” (IBSNAT) en la década de los 80, y STICS¹⁴, que fue creado en el INRA¹⁵ en el año 1996, simulan el crecimiento y el desarrollo del cultivo, su rendimiento, así como el agua del suelo y los balances de nitrógeno. Además, los modelos DSSAT incluyen la dinámica del carbono, pero no tiene en cuenta algunos factores limitantes como es el caso de las diferentes plagas o las limitaciones del suelo.

Dentro de los modelos de DSSAT, se pueden destacar el modelo Crop Environment REsource Synthesis (CERES; Ritchie et al. 1988, Godwin et al. 1989, Singh et al. 1991) que fue diseñado para modelar el crecimiento y el desarrollo de cereales como la cebada, el trigo, el arroz, el maíz y el sorgo. La versión para el trigo (CERES-wheat), simula el crecimiento y el desarrollo del trigo, y su rendimiento teniendo en cuenta los efectos del clima, la genética, el suelo, la siembra, el riego y el manejo de fertilizantes de nitrógeno (Ritchie et al. 1998).

Por otro lado, APSIM¹⁶ ha sido desarrollado por la Unidad de Investigación de Sistemas de Producción Agrícola (APSRU) en Australia para simular con exactitud el rendimiento del cultivo y los procesos biofísicos del suelo, así como los cambios en el pH, en el balance de agua y en el nitrógeno, entre otros. Y CropSyst¹⁷ fue creado por el Departamento de Ingeniería de Sistemas Biológicos de la Universidad Estatal de Washington para investigar el impacto del clima, del suelo y la gestión de la productividad en los cultivos. Este modelo se caracteriza porque utiliza la misma metodología para simular el crecimiento y desarrollo de todos los cultivos. Sin embargo, algunos aspectos de la evaluación del modelo se ven limitados por la escasa disponibilidad de datos, lo que provoca que sea difícil establecer el verdadero rendimiento del modelo (Stöckle et al. 2003).

¹⁴ Acrónimo del término inglés Standard mulTidisciplinary Simulator for Crops.

¹⁵ Siglas del término francés L’Institut national de la recherche agronomique.

¹⁶ Acrónimo del término inglés Agricultural Production Systems Simulator model.

¹⁷ Acrónimo del término inglés Cropping Systems Simulation Model.

Capítulo 1. Estado del conocimiento

CAPÍTULO 2

Motivación y objetivos



2.1. Motivación y objetivos de la investigación

Este capítulo se centra en mostrar la hipótesis de partida, los motivos y los objetivos que se persiguen para llevar a cabo esta investigación.

2.1. Motivación y objetivos de la investigación

La variabilidad y el cambio climático son temas de investigación relevante, principalmente por su impacto en los ecosistemas. Para evaluar el riesgo de los ecosistemas ante el fenómeno del cambio climático es necesario comprender y cuantificar los impactos. El Panel Intergubernamental sobre el cambio climático (IPCC; IPCC 2013) prepara informes especiales sobre el impacto del aumento de la temperatura global y la vulnerabilidad de los ecosistemas. Para ello, se requieren resultados y estimaciones cuantitativas sobre las relaciones clima-ecosistemas.

Un sector de indudable interés es el agrícola. Por ello, una de las cuestiones que suscitó el desarrollo de este trabajo fue la determinación de la influencia de la variabilidad climática en producciones agrícolas puesto que la influencia de la meteorología en la agricultura es evidente. El problema que se planteaba investigar era complejo debido a que hay otros factores socioeconómicos difíciles de cuantificar y separar de la contribución del clima. Para desarrollar este estudio fue necesario identificar la información relevante y construir modelos para representar el fenómeno. En el Capítulo 1 se ha introducido los modelos agrícolas, basados en procesos y estadísticos, para conocer los efectos del clima en la agricultura (Lobell & Burke 2010, Moore & Lobell 2014, Ramirez-Villegas & Challinor 2012, Watson et al. 2015, entre otros). Los modelos no sólo son de gran utilidad para analizar el impacto del cambio climático, sino para poder adoptar estrategias que mitiguen las pérdidas en las cosechas (IPCC 2014).

Dado el interés del tema, numerosos estudios dedican esfuerzos para investigar el impacto del cambio climático y la variabilidad climática en las producciones agrícolas a nivel global, nacional y regional (Gornall et al. 2010, White et al. 2011, Lobell & Gourdjji 2012, Chen et al. 2015, Lesk 2016, entre otros). La mayoría de estas investigaciones agroclimáticas se centran en analizar las relaciones entre los cultivos, la precipitación y la temperatura (Challinor et al. 2014, Lobell 2007, Trnka et al. 2014, Eitzinger et al. 2013, entre otros). Por otro lado, numerosos estudios han considerado los efectos en la agricultura de variables climáticas a gran escala, relacionados con la circulación atmosférica y la temperatura de la superficie del mar y, además, representadas mediante

patrones de teleconexión (Hansen et al. 2004, Podesta et al. 2002, Cantelaube et al. 2004, Atkinson et al. 2005, Dalla Marta et al. 2011, Jarlan et al. 2014, entre otros). Sin embargo, los resultados sobre los impactos son inciertos por imprecisiones de las simulaciones, no sólo de los modelos agrícolas sino también de los modelos climáticos. Por ello, es importante evaluar las proyecciones dadas por diferentes modelos elaborados con metodologías diferentes.

Dentro de las producciones agrícolas de España el trigo tiene gran interés como se indicó en el capítulo anterior. Sin embargo, las evaluaciones de los efectos de las variaciones climáticas en el trigo y cereales sólo han sido estudiadas en regiones puntuales (Gimeno et al. 2002, Vicente-Serrano et al. 2006, Iglesias & Quiroga 2007, Rodríguez-Puebla et al. 2007, Ruiz-Ramos et al. 2011, Capa-Morocho et al. 2016). Por todo ello, es importante revisar el estudio y actualizar con nuevos datos y metodologías.

Un aspecto muy importante de esta investigación es su utilidad. Las pérdidas en la agricultura debido a las catástrofes naturales en la última década han aumentado considerablemente. Particularmente, en el año 2017 la sequía ha ocasionado una reducción entre el 30 y 40 % de la cosecha de cereales respecto al año 2016. Por ello, es necesario entender los impactos del cambio climático en la agricultura, para poder anticipar cómo el cambio climático afectará a la disponibilidad de alimentos. Los seguros agrarios tienen como objetivo ofrecer protección a las producciones agrarias frente a los riesgos naturales no controlables (condiciones climáticas adversas, accidentes o enfermedades), y así apoyar a la sostenibilidad financiera de la agricultura. En España, el sistema de seguros agrarios se encarga de gestionar los riesgos producidos en las explotaciones agrarias y para ello necesita la ayuda de entidades e instituciones públicas y privadas que sean capaces de aportar medidas de prevención y adaptación para la agricultura frente al cambio climático, desarrollando modelos que contribuyan a la mejora de las condiciones productivas en el medio rural.

Así pues, los objetivos principales de esta tesis doctoral son, por un lado, encontrar las relaciones entre la variabilidad del trigo en España y los procesos climáticos y por otro, proyectar la productividad de trigo bajo los escenarios del cambio climático. La consecución de estos objetivos supone dotar, tanto a la comunidad científica como a los diferentes sectores agrícolas, información sobre la vulnerabilidad del trigo en España al cambio climático y poder así desarrollar estrategias de adaptación. Para tal fin, en esta investigación se propone el uso de nuevos métodos: por una parte, la descomposición empírica en modos por conjuntos (EEMD) para separar el efecto de las mejoras tecnológi-

2.1. Motivación y objetivos de la investigación

cas respecto a los efectos climáticos en la variabilidad del trigo y determinar las tendencias de las proyecciones de trigo; y por otra, la regresión de mínimos cuadrados parciales (PLS) para identificar la co-variabilidad entre el clima y el rendimiento del trigo. Estos métodos podrán aplicarse para investigaciones posteriores centradas en el estudio del impacto del cambio climático en otras producciones agrícolas en España o bien para estudios de impacto en otros lugares.

En esta investigación, estos objetivos generales se dividen en tres objetivos específicos, correspondiendo cada uno de ellos a una publicación adjunta en el Capítulo 5. Por lo tanto, a continuación se detallan las cuestiones planteadas que tratan de responder a cada uno de los objetivos.

1. Analizar la respuesta del rendimiento del trigo en España a los procesos climáticos, utilizando variables climáticas de escala regional y métodos estadísticos y proyectar el rendimiento del trigo bajo los escenarios del cambio climático.
 - ◊ ¿Qué variables climáticas o procesos derivados en escala regional son esenciales para explicar los cambios en el rendimiento del trigo?
 - ◊ ¿Qué tendencias experimentará el rendimiento del trigo considerando estos hallazgos con respecto a estas variables?

Las respuestas a estas preguntas se encuentran disponibles en la sección 5.1 del Capítulo 5: Efectos del rango térmico diario y sequía en la productividad del trigo en España / Effects of diurnal temperature range and drought on wheat yield in Spain (Hernández-Barrera et al. 2016).

2. Mejorar la confianza de las proyecciones del rendimiento del trigo en España, utilizando variables a gran escala.
 - ◊ ¿Cuál es la mejor clasificación para reflejar los diferentes comportamientos del rendimiento del trigo en España?
 - ◊ ¿Cuál es la asociación entre el rendimiento de trigo y las variables climáticas a gran escala?
 - ◊ ¿Son adecuados los modelos empíricos basados en variables a gran escala para simular el rendimiento de trigo?
 - ◊ ¿Se puede disminuir la incertidumbre de las tendencias proyectadas con modelos empíricos basados en variables a gran escala respecto a las variables regionales?

Capítulo 2. Motivación y objetivos

Las respuestas a estas preguntas se encuentran disponibles en la sección 5.2 del Capítulo 5: El rendimiento del trigo en España y su asociación con los patrones de radiación solar / Wheat yield in Spain and associated solar radiation patterns (Hernández-Barrera & Rodríguez-Puebla 2017).

3. Analizar el rendimiento del trigo en España utilizando las simulaciones del modelo agrícola basado en procesos GLAM.
 - ◊ ¿Es adecuado el modelo de cultivo GLAM para representar la variabilidad del rendimiento de trigo en España?
 - ◊ ¿Las simulaciones con GLAM dan cuenta de la influencia de los modos de variabilidad climática de forma similar a como quedaron representadas por el rendimiento de trigo observado?
 - ◊ ¿Cuál es la tendencia que proyecta GLAM para el rendimiento de trigo?
 - ◊ ¿Cuál es la incertidumbre de las proyecciones de tendencia dada mediante GLAM en comparación con la de los modelos empíricos?

Las respuestas a estas preguntas se encuentran disponibles en la sección 5.3 del Capítulo 5: Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España / Assessing GLAM-wheat simulation to estimate variability and trend of wheat yield in Spain (en revisión).

Para alcanzar todos los objetivos expuestos anteriormente, esta tesis doctoral se estructura en 6 capítulos. En el Capítulo 1 se ha introducido el estado del conocimiento de los temas a tratar en esta investigación, presentando una descripción acerca del cultivo del trigo, de su origen y su historia hasta llegar a su estado actual, del trigo en España, de las relaciones clima-trigo, así como la variabilidad climática en España, y los modelos agroclimáticos. En este capítulo se han expuesto los motivos y los objetivos de esta investigación. El Capítulo 3 mostrará de forma detallada los datos que se han utilizado en esta investigación y el tratamiento de los datos previo a la aplicación de la metodología. En el Capítulo 4 se detallarán los métodos aplicados, explicando en profundidad EEMD¹ y la regresión PLS². Además, se describirá el modelo agrícola GLAM. El Capítulo 5 se centra en los resultados de la investigación y contendrá las

¹Acrónimo del término inglés Ensemble Empirical Mode Decomposition.

²Acrónimo del término inglés Partial Least Squares.

2.1. Motivación y objetivos de la investigación

publicaciones científicas que ha dado lugar, incluyendo un resumen de las mismas en castellano. Finalmente, en el Capítulo 6 se mostrarán las conclusiones más relevantes de esta tesis doctoral y el trabajo futuro proyectado.

Capítulo 2. Motivación y objetivos

CAPÍTULO 3

Datos



3.1. Trigo de invierno

Este capítulo se centra en la descripción de los datos y la preparación de los mismos para el desarrollo de la investigación. El capítulo se divide en cuatro secciones de acuerdo con las características de los datos. La sección 3.1 describe los datos observados del trigo de invierno en España. La sección 3.2 se centra en los datos climáticos “pseudo-observados” y de reanálisis utilizados para la obtención de los modelos de cultivo empíricos y basado en procesos. La sección 3.3 describe los patrones de teleconexión climática que se han utilizado para interpretar las influencias del clima en las producciones. Por último, la sección 3.4 muestra la descripción de las variables climáticas de las simulaciones CMIP5 utilizadas en la investigación para obtener proyecciones del rendimiento de trigo.

3.1. Trigo de invierno

Tanto para obtener modelos como para evaluarlos son necesarios datos observados del cultivo. Para realizar esta investigación se han recopilado series históricas del rendimiento del trigo a nivel nacional y a nivel geográfico de Provincias. Estos datos se encuentran disponibles a través de la página web¹ del Ministerio de Agricultura, Alimentación y Medio Ambiente (MAGRAMA) en los anuarios Estadísticos.

La serie histórica del rendimiento del trigo para toda España comprende el periodo desde 1979 hasta el 2014. La evolución del rendimiento del trigo de España se muestra en la Figura 1.3 del Capítulo 1, donde se puede observar que el rendimiento del trigo presenta una tendencia creciente a lo largo del periodo. Por lo que, la componente de tendencia se filtra porque interfiere para desarrollar los objetivos de esta investigación. Un inconveniente es que no disponemos de métodos que permitan diferenciar entre la tendencia debida a la tecnología de la correspondiente al cambio climático y al aumento de CO_2 . Además, diversos estudios, como por ejemplo el de Asseng et al. 2013 ponen en duda los efectos beneficiosos del aumento de CO_2 . En definitiva, para realizar este estudio se ha filtrado la componente de tendencia del rendimiento del trigo. Para ello se aplicó el método “Ensemble Empirical Mode Decomposition” (EEMD; Huang et al. 1998), que se explica en el Capítulo 4. Por lo tanto, trabajaremos con las anomalías de rendimiento de trigo respecto a la componente de tendencia.

¹<http://www.mapama.gob.es/es/>

A nivel geográfico de provincias se ha estudiado el rendimiento de trigo de 48 provincias de toda España en el periodo 1980-2014. Al igual que se hizo con la serie histórica del rendimiento del trigo de España, la tendencia del rendimiento de trigo de cada provincia fue filtrada aplicando el método EEMD. Además, a estos datos se les ha aplicado el método de agrupamiento K-means (explicado en el Capítulo 4) para clasificar el trigo según su comportamiento y de este modo, destacar las señales de variabilidad respecto a errores de las medidas o anomalías de difícil interpretación. La clasificación proporcionó dos zonas (ver Capítulo 5), que se indican con diferente coloreado en la Figura 3.1 Asimismo, esta figura muestra el rendimiento medio del trigo y el coeficiente de variación de las diferentes provincias de España.

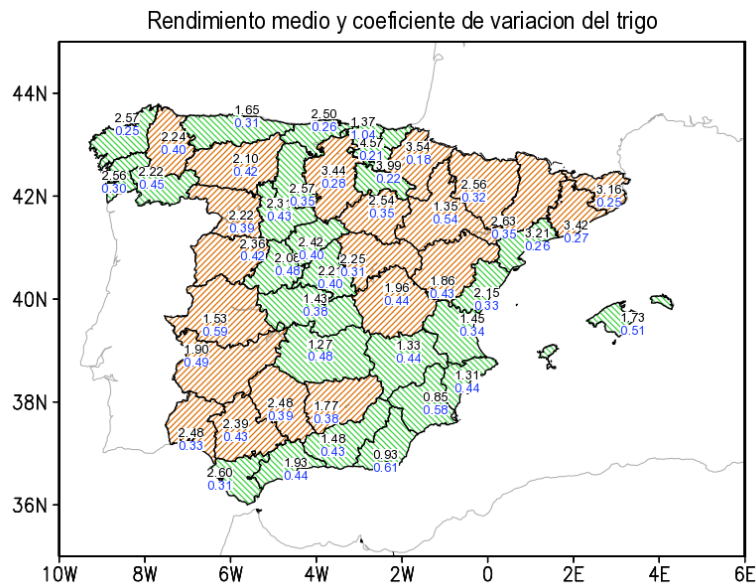


Figura 3.1: Distribución espacial del rendimiento de trigo en España, los números negros indican el rendimiento medio del trigo y los números en azules el coeficiente de variación. El patrón de color verde corresponde con la región 1 y el patrón marrón con la región 2

La Figura 3.2 resume la evolución del rendimiento de trigo en las dos zonas previamente clasificadas. Se observa mayores valores de rendimiento y mayor tendencia en la región 2.

3.2. Datos climáticos




Figura 3.2: Serie temporal del rendimiento de trigo espacialmente promediado en las dos regiones (barras) para el periodo 1980-2014. Las líneas corresponden a la tendencia no lineal

3.2. Datos climáticos

3.2.1. Datos de precipitación y temperatura

Como se ha mencionado en el Capítulo 1, Estado del conocimiento, la temperatura y la precipitación son las variables climáticas que se consideran básicamente en estudios agroclimáticos. Si bien existen observaciones “in situ”, para este trabajo necesitábamos datos que estimasen las condiciones climáticas del área provincial correspondiente a la producción del trigo. Las opciones disponibles eran el uso de Spain02 (Herrera et al. 2012) o E-OBS² (Haylock et al. 2008). Spain02 ofrece datos con mayor resolución, sin embargo, cuando se inició este trabajo los datos no abarcaban el periodo completo correspondiente a la producción de trigo. Por ello, desarrollamos el estudio con los datos E-OBS. Este conjunto de datos han sido desarrollados y financiados por los proyectos ENSEMBLES (EU-FP6³) y EURO4M⁴ (EU-FP7⁵). Actualmente, son confeccionados por el proyecto UERRA⁶ (EU-FP7) y se encuentran disponibles de

² Acrónimo del término inglés European daily high-resolution gridded data set.

³ Acrónimo del término inglés European Union-Sixth Framework Programme for Research and Technological Development.

⁴ Acrónimo del término inglés European Reanalysis and Observations for Monitoring.

⁵ Acrónimo del término inglés European Union-Seventh Framework Programme for Research and Technological Development.

⁶ Acrónimo del término inglés Uncertainties in Ensembles of Regional ReAnalyses.

manera gratuita en la página web⁷ European Climate Assessment & Dataset (ECA&D).

E-OBS proporciona datos de precipitación, temperatura (Haylock et al. 2008) y datos de presión al nivel del mar (van den Besselaar et al. 2011). Esta base de datos se actualiza con frecuencia, la versión más reciente es la 15.0, la cual abarca desde el 1 de enero de 1950 hasta el 31 de diciembre de 2016. En general, estos datos son obtenidos por la interpolación de más de 2300 observatorios de toda Europa. Los datos están disponibles para mallas regulares con una resolución de 0.25° o de 0.5° y para mallas rotadas con una resolución de 0.22° y 0.44°, con el polo norte en 39.25°N y 162°W. La interpolación de estos datos se basa en la combinación de las estimaciones mensuales y diarias. Para llevar a cabo tal objetivo, se interpolan, por un lado, las medias mensuales de precipitación y temperatura aplicando la técnica de interpolación “Thin plate splines” (TPS) y por otro, las anomalías diarias con respecto a las medias mensuales aplicando el método “kriging”, para luego ser combinadas entre sí (Hutchinson 1993). De esta manera, cada malla no representa a una estación puntual sino el promedio de un área. Por ello, se puede decir que son datos climáticos pseudo-observados con una alta resolución cuadriculada.

En esta tesis doctoral se utilizan los datos diarios de precipitación, temperatura media, máxima y mínima con una resolución de 0.25° pertenecientes a las versiones 11 y 13, según los artículos. El efecto de las versiones no produce cambios por lo que respecta al clima de la Península Ibérica como se muestra en las comparaciones⁸. Estos datos han sido seleccionados para la región de España (35-45°N y 10°W-5°E) y para el periodo desde septiembre de 1978 hasta mayo de 2014. Los datos diarios presentaban algunas inconsistencias por lo que respecta a las temperaturas máximas y mínimas, debido a que el efecto de la interpolación causaba que en algunos lugares y días las temperaturas mínimas fuesen superiores a las máximas. Esto fue corregido para que la diferencia fuese cero. A partir de las temperaturas diarias se ha derivado la diferencia entre temperatura máxima y mínima, o lo que es lo mismo el DTR. De los datos diarios se obtuvieron los promedios mensuales y estacionales. A partir de los datos diarios de precipitación, se ha obtenido el acumulado de precipitación, también en escala de tiempo mensual y estacional, y a partir de la precipitación mensual, se derivó el SPI (WMO 2012, Vicente-Serrano et al. 2010) para la escala temporal de 1 mes, y así reflejar la respuesta del trigo a

⁷<http://www.ecad.eu/>

⁸http://cib.knmi.nl/mediawiki/index.php/Compare_EOBS_v14.0_and_v13.1

3.2. Datos climáticos

los eventos de sequías repentinas (Otkin et al. 2015) o a las sequías agrícolas (Lorenzo-Lacruz et al. 2013). El índice SPI consiste en la cuantificación de la precipitación acumulada para una determinada escala temporal, ajustándose a una distribución normal (McKee et al. 1993, Edwards & McKee 1997). En nuestro caso, el SPI fue obtenido con un script de Ncar Command Language (NCL) (UCAR/NCAR 2015). Asimismo, como las variables climáticas afectan al rendimiento del trigo de diferente manera según la estación, se han agrupado las variables climáticas en diferentes etapas: otoño (SON⁹) del año previo a la producción, definida como el promedio de los meses de septiembre a noviembre; invierno (DJF¹⁰), definida como el promedio de los meses de diciembre a febrero y primavera (MAM¹¹), definida como el promedio de los meses de marzo a mayo. De esta manera podemos evaluar las relaciones entre el rendimiento de trigo y las variables climáticas, de forma que cubra la cosecha del trigo desde la siembra hasta su recolección.

3.2.2. Datos de reanálisis: ERA-Interim y ERSST v3b

Los datos de reanálisis son unos de los más utilizados en estudios meteorológicos y climáticos. Se obtienen mediante métodos de asimilación, o técnicas que se aplican a datos observados y predicciones de modelos numéricos. Se utilizan tanto para estudiar la dinámica atmosférica como en estudios de variabilidad, así como para evaluar los modelos climáticos (Parker 2016). En general, los datos de reanálisis proporcionan estimaciones tridimensionales de variables atmosféricas, en superficie, en diferentes niveles y de la temperatura superficial del mar. Las características principales que distinguen a cada reanálisis son el modelo que se utiliza para su obtención y el conjunto de datos observacionales que asimila, además de la cobertura temporal y la resolución espacial.

En la actualidad, en el campo de las ciencias atmosféricas se encuentran disponibles diferentes reanálisis, entre los que destacan: el reanálisis de NCEP¹²/NCAR¹³ (Kalnay et al. 1996); el reanálisis MERRA¹⁴ (Rienecker et al. 2011); el reanálisis 20th Century (20CR; Compo et al. 2011); los reanálisis ERA-40 (Uppala et al. 2005); ERA-Interim (Dee et al. 2011); el reanálisis JRA-55¹⁵

⁹ Acrónimo del término inglés September-October-November.

¹⁰ Acrónimo del término inglés December-January-February.

¹¹ Acrónimo del término inglés March-April-May.

¹² Siglas del término inglés National Centers for Environmental Prediction.

¹³ Siglas del término inglés National Center for Atmospheric Research.

¹⁴ Acrónimo del término inglés Modern-Era Retrospective Analysis for Research and Applications.

¹⁵ Acrónimo del término inglés Japanese 55-year Re-Analysis.

(Kobayashi & Iwasaki 2016) y el reanálisis ERSST¹⁶ v3b y v4¹⁷ (Smith et al. 2008, Huang et al. 2015). La mayoría de estos reanálisis sólo disponen de datos desde la mitad del siglo XX hacia delante, esto se debe a que es el único periodo para el que existen suficientes datos observacionales de la atmósfera media. El nombre oficial de los reanálisis, la institución a la que pertenecen y las principales características de estas bases de datos se detallan en la Tabla 3.1. Sin embargo, en esta investigación sólo se han utilizado aquellos reanálisis que mejor se ajustaban a nuestra investigación, por ello, hemos seleccionado el reanálisis ERA-Interim para datos atmosféricos por su mayor resolución, y el reanálisis ERSST v3b y v4 para la temperatura superficial del mar.

El reanálisis ERA-Interim es el proyecto más reciente de ECMWF¹⁸, actualmente está en preparación el reanálisis ERA5. ERA-Interim abarca desde 1979 en adelante, actualizándose una vez al mes, pero lleva un retraso de dos meses para poder realizar un control de calidad y corregir los posibles problemas técnicos que aparezcan (Dee et al. 2011). Las variables utilizadas en este trabajo de investigación han sido la radiación solar en superficie (SSRD) a escala diaria y mensual, la altura geopotencial en el nivel de 500 hPa (Z500), la presión al nivel del mar (MSL) y el viento horizontal 250 hPa (U250). Estos datos han sido seleccionados para la región comprendida entre las latitudes y longitudes 20-80°N y 60°W-30°E y para el periodo comprendido desde septiembre de 1979 hasta agosto de 2014. Los datos del ERA-Interim pueden obtenerse a través de la página web¹⁹ ECMWF o desde “The Meteorological Archival and Retrieval System” (MARS). Además del ERA-Interim, ECMWF ha desarrollado diferentes bases de datos: la primera fue el ERA-15, el cual genera un reanálisis de aproximadamente 15 años, que abarca desde diciembre de 1978 a febrero de 1994. Y la segunda fue el ERA-40, que en un principio era una base de datos que recogía el reanálisis de 40 años, pero finalmente abarcó 45 años, estos datos cubren el periodo 1957-2002.

El reanálisis ERSST v3b, incorpora de forma global, un análisis de la temperatura superficial del mar mensual, que abarca desde enero de 1854 hasta la actualidad e incluye las anomalías calculadas con respecto a la climatología mensual del periodo 1971-2000. Esta base de datos es derivada del “International

¹⁶ Acrónimo del término inglés Extended Reconstructed Sea Surface Temperature-version 3b.

¹⁷ Acrónimo del término inglés Extended Reconstructed Sea Surface Temperature-version 4.

¹⁸ Siglas del término inglés European Centre for Medium-Range Weather Forecasts.

¹⁹ <http://www.ecmwf.int/>

3.2. Datos climáticos

Tabla 3.1: Características de los reanálisis más destacados. La primera columna indica el nombre del reanálisis. La segunda columna muestra el nombre de la institución a la que pertenecen. La tercera columna indica el periodo disponible de los datos. La cuarta columna muestra la resolución de datos de reanálisis y la quinta columna muestra los perfiles disponibles de cada reanálisis

Análisis	Institución	Periodo	Resolución	Datos asimilados
NCEP/NCAR	National Centers for Environmental Prediction / National Center for Atmospheric Research	1948-presente	2.5°x2.5° / 2°x2°	Perfiles verticales de viento y temperatura
MERRA	Global Modeling and Assimilation Office	1979-presente	21.25°x1.25°	Perfiles verticales y de superficie
20CR	Multinational Project “Twentieth Century Reanalysis”	1871-2010	2°x2°	Perfiles de superficie
ERA-40	European Centre for Medium-Range Weather Forecasts (ECMWF)	1957-2002	2.5°x2.5° / 1.125°x1.125°	Perfiles verticales y de superficie
ERA-Interim	European Centre for Medium-Range Weather Forecasts (ECMWF)	1979-presente	0.75°x0.75°	Perfiles verticales y de superficie
JRA-55	Japan Meteorological Agency	1958-presente	1.25°x1.25°	Perfiles verticales y de superficie
ERSST v3b	International Comprehensive Ocean–Atmosphere Dataset	1854-presente	2°x2°	Temperatura superficial del mar

Comprehensive Ocean–Atmosphere Dataset” y se encuentran disponibles en la página web²⁰ del NOAA²¹-National Climatic Data Center. Esta versión presenta algunas mejoras con respecto a la versión ERSST v3. No se han incluido las muestras de los promedios globales, ni se han incluido los datos de satélites, debido a que estos datos presentaban una tendencia hacia el frío lo suficientemente importante como para cambiar la clasificación de los meses. Actualmente, existe una versión más reciente (ERSST v4), que utiliza los datos de la versión ERSST v3b, pero incluye una mejora con respecto a la integridad espacial. En concreto, estos datos han sido seleccionados para la región del Atlántico (0-60°N y 60°W-30°E) y para la región del Pacífico (30°S-30°N y 100°E-60°W) y para el mismo periodo que los datos del reanálisis ERA-Interim.

Del mismo modo que se hizo con los datos observacionales, los datos de reanálisis fueron agrupados por estaciones (SON, DJF y MAM). Además, a todos los datos se les ha eliminado la tendencia lineal y se han ponderado por el coseno de la latitud antes de aplicar la metodología para evitar el efecto de los diferentes tamaños de las celdas con respecto a la latitud.

3.3. Índices de teleconexión

Los patrones de teleconexión son estructuras persistentes a gran escala de las anomalías de presión y circulación que se expanden por vastas zonas geográficas. Se repiten de forma periódica, pudiendo durar varias semanas o meses, e incluso años (Walker & Bliss 1928, Van Loon & Rogers 1978, Wallace & Gutzler 1981, Barnston & Livezey 1987). Los patrones de teleconexión reflejan cambios a gran escala en las ondas atmosféricas y en las corrientes en chorro, influyendo en la temperatura, la precipitación, en la trayectoria de las tormentas y en la localización e intensidad de la corriente en chorro. Por lo tanto, son a menudo los responsables del comportamiento interrelacionado de las anomalías climáticas en regiones distantes.

En la actualidad, los patrones de teleconexión están disponibles en el Earth System Research Laboratory (ESRL) de la NOAA ²². De entre todos los centros de investigación, el CPC²³ supervisa los principales patrones de teleconexión e investiga el papel que desempeñan en el sistema climático global. Este centro

²⁰<https://www.ncdc.noaa.gov/>

²¹ Acrónimo del término inglés National Oceanic and Atmospheric Administration.

²²<https://www.esrl.noaa.gov/>

²³ Acrónimo del término inglés Climate Prediction Center.

3.4. Datos CMIP5

identifica diez patrones teleconectivos en las regiones extratropicales del hemisferio norte a lo largo del año, los cuales han sido definidos previamente en la literatura científica por Barnston & Livezey (1987). A su vez, el CPC aplica la misma metodología que Barnston & Livezey (1987), el Análisis de Componentes Principales Rotadas (RPCA²⁴), para obtener los patrones teleconectivos. Además, los índices de teleconexión mensuales están disponibles desde 1950 hasta la actualidad. Toda la información de los índices de teleconexión, así como el procedimiento del cálculo de los mismo y las configuraciones de los mapas espaciales están disponibles en la página web²⁵ del CPC.

De todos los índices de teleconexión mensuales disponibles en ESRL de la NOAA, en esta investigación sólo se han utilizado algunos de los que presentan mayor influencia en la región euro-Atlántica, que son la Oscilación del Atlántico Norte (NAO²⁶), el patrón del Este del Atlántico (EA²⁷), el patrón de Escandinavia (SCAND²⁸), el patrón de Oscilación Multidecadal del Atlántico (AMO²⁹). Además, se ha utilizado el índice de El Niño en la región 3.4 (EN-SO³⁰). Todos los índices de teleconexión han sido calculados para la estación de otoño (SON), de invierno (DJF) y de primavera (MAM) como promedios de los meses de septiembre a noviembre, de diciembre a febrero y de marzo a mayo, respectivamente, para el periodo que abarca desde septiembre de 1979 hasta mayo de 2014. Estos índices se correlacionan con los principales modos de variabilidad de la SSRD³¹, de la MSL³², del Z500³³, del U250³⁴ y de la SST³⁵ asociados con el rendimiento del trigo (ver Capítulo 4), para confrontar si estos modos integran los efectos de teleconexión (como se muestra en el capítulo de resultados).

3.4. Datos CMIP5

El Proyecto de intercomparación de modelos acoplados (CMIP³⁶) fue crea-

²⁴ Acrónimo del término inglés Rotated Principal Component Analysis.

²⁵ <http://www.cpc.noaa.gov/>

²⁶ Acrónimo del término inglés North Atlantic Oscillation.

²⁷ Acrónimo del término inglés East Atlantic pattern.

²⁸ Acrónimo del término inglés Scandinavia pattern.

²⁹ Acrónimo del término inglés Atlantic Multidecadal Oscillation.

³⁰ Acrónimo del término inglés El Niño-Southern Oscillation.

³¹ Acrónimo del término inglés Surface Solar Radiation.

³² Acrónimo del término inglés Sea Level Pressure.

³³ Acrónimo del término inglés Geopotential height at 500 hPa.

³⁴ Acrónimo del término inglés Zonal Wind at 250 hPa.

³⁵ Acrónimo del término inglés Sea Surface Semperature.

³⁶ Acrónimo del término inglés Coupled Model Intercomparison Project.

do en 1995 por el Grupo de trabajo de modelos acoplados (WGCM³⁷) del “Joint Scientific Committee/Climate Variability and Predictability” (JSC/CLIVAR), dentro del Programa mundial de investigaciones climáticas (WCRP³⁸), para el estudio de los modelos de circulación general acoplados océano-atmósfera (AOGCMs³⁹). Los modelos AOGCMs proporcionan información acerca de futuros escenarios climáticos. Por lo tanto, el objetivo del proyecto CMIP es proporcionar una base de datos con variables obtenidas a partir de las salidas de AOGCMs a los que se fijan unas condiciones de contorno estándar. Esto permite a la comunidad científica analizar las salidas de los modelos de circulación de una forma sistemática, lo que facilita la introducción de mejoras en dichos modelos. Desde el comienzo de este proyecto en 1995, se han llevado a cabo diversas fases del proyecto, conocidas como CMIP1⁴⁰, CMIP2⁴¹, CMIP3⁴² y CMIP5⁴³, siendo esta última la más reciente. Actualmente está en preparación la fase CMIP6⁴⁴ para los próximos informes del IPCC.

Para realizar esta investigación se han utilizados los datos pertenecientes a la fase CMIP5. Estos datos están disponibles, de manera gratuita para proyectos de investigación. Se puede acceder a ellos desde diversos nodos acogidos por “Department of Energy Lawrence Livermore National Laboratory”. En la página web⁴⁵ del “Program for Climate Diagnosis and Intercomparison” (PCMDI), se proporcionan no sólo datos, sino herramientas para el diagnóstico y la evaluación de los modelos climáticos. Además, se puede encontrar una descripción general de las simulaciones de CMIP5.

Los CMIP5 incluyen simulaciones de control, las simulaciones Historical y de clima futuro (Taylor et al. 2012). Para las simulaciones de clima futuro existen 4 escenarios de emisiones diferentes (Moss et al. 2010), uno de ellos no presenta mitigación y los otros tres tienen diferentes niveles de mitigación. Todos ellos se conocen como “Representative Concentration Pathways” (RCPs), los cuales comienzan en el año 2006 y terminan en el año 2100. Además, a los RCPs⁴⁶ se les etiqueta con un sufijo numérico que indica el forzamiento radiativo aproximado en el año 2100. Por ejemplo, RCP4.5 es un escenario de

³⁷ Acrónimo del término inglés Working Group on Coupled Modelling.

³⁸ Acrónimo del término inglés World Climate Research Program.

³⁹ Acrónimo del término inglés Atmosphere-Ocean General Circulation Model.

⁴⁰ Acrónimo del término inglés Coupled Model Intercomparison Project Phase 1.

⁴¹ Acrónimo del término inglés Coupled Model Intercomparison Project Phase 2.

⁴² Acrónimo del término inglés Coupled Model Intercomparison Project Phase 3.

⁴³ Acrónimo del término inglés Coupled Model Intercomparison Project Phase 5.

⁴⁴ Acrónimo del término inglés Coupled Model Intercomparison Project Phase 6.

⁴⁵ <http://www-pcmdi.llnl.gov/>

⁴⁶ Acrónimo del término inglés Representative Concentration Pathways.

3.4. Datos CMIP5

mitigación media que identifica una trayectoria de concentraciones que alcanza un forzamiento de 4.5 Wm^{-2} aproximadamente, en el año 2100, relativo a las condiciones preindustriales.

En esta tesis doctoral se ha utilizado la simulación Historical y la RCP8.5. La simulación Historical, conocidas como simulación del clima del siglo XX, engloba el periodo comprendido entre 1850-2005 e incluye los forzamientos observados de la composición atmosférica, tanto el origen antropogénico como el natural, el forzamiento solar y el forzamiento del uso de la cubierta terrestre. La simulación RCP8.5 simula el clima futuro en el periodo 2006-2100 y considera un forzamiento radiativo que alcanza un 8.5 Wm^{-2} aproximadamente, en el año 2100 (Riahi et al. 2011), relativo a las condiciones preindustriales. Estas dos simulaciones, la simulación Historical y RCP8.5, se han unido formando una única serie de datos, a la que se aplica la metodología utilizada. Este procedimiento se ha llevado a cabo en cada modelo utilizado. Además, de todas las realizaciones disponibles en la página web del PCMDI⁴⁷ para cada modelo. Sólo se ha utilizado la primera realización de cada modelo para dar a todos los modelos del mismo peso.

Por un lado, se han seleccionados las variables climáticas mensuales y diarias de precipitación, temperatura media, máxima y mínima y la radiación solar de 12 modelos CMIP5. Estos modelos se especifican en la Tabla 3.2 y en el Apéndice A. En este caso, se ha considerado la simulación Historical para el periodo comprendido desde septiembre de 1901 hasta diciembre de 2005 y la simulación RCP8.5 para el periodo 2006-2100. Además, debido al uso del índice SPI y el DTR en esta investigación, estos han sido derivados de igual modo que en el caso de los datos pseudo-observacionales. Por otro lado, se han utilizado los datos diarios de las variables de precipitación, temperatura máxima y mínima y la radiación solar de 9 modelos CMIP5. En este caso, el número de modelos se ha reducido a consecuencia de que no se disponen de los datos diarios de la radiación solar para todos los modelos seleccionados anteriormente. Los modelos utilizados en esta parte se han marcado con un * en la Tabla 3.2 y en el Apéndice A. Por el mismo motivo, la simulación Historical sólo comprende el periodo septiembre de 1951 a diciembre del 2005, manteniéndose el mismo periodo de la simulación RCP8.5.

Por requisitos metodológicos, todos los modelos CMIP5 fueron remallados a una malla común coincidente con la de los datos observaciones y de reanálisis, mediante el uso de la interpolación bilineal del paquete de software Operadores

⁴⁷Acrónimo del término inglés Program for Climate Diagnosis and Intercomparison.

de datos climáticos (CDO⁴⁸) (Schulzweida 2015). Además, todos los datos han sido pesados por el coseno de la latitud con el fin de compensar la convergencia de meridiano.

Tabla 3.2: Modelos CMIP5 utilizados en esta investigación. La primera columna indica el acrónimo del modelo. La segunda columna muestra la resolución atmosférica (celda horizontal y número de niveles verticales). Y la tercera columna muestra la referencia del modelo

Acrónimo del modelo	Resolución Atmosférica	Referencia
CCSM4*	0.9°x1.25°, L27	Gent et al. (2011) Bitz (2012)
CESM1-CAM5	0.9°x1.25°, L27	Hurrell et al. (2013)
CMCC-CESM*	1.875°x1.875° (T63), L95°	Fogli et al. (2009)
CNRM-CM5*	TL127, L31	Voldoire et al. (2013)
CanESM2	Espectral T63, L35	von Salzen et al. (2013)
GFDL-ESM2M*	2.0°x2.5° M45, L24	Dunne et al. (2013)
GISS-E2-H	2.0°x2.5°, L40	Schmidt et al. (2014)
HadGEM2-CC*	1.25°x1.875°, N96, L60	Collins et al. (2011) Martin et al. (2011)
HADGEM2-ES*	1.25°x1.875°, N96, L38	Collins et al. (2011) Martin et al. (2011)
MIROC5*	1.40625° x 1.40625°, T85, L40	Watanabe et al. (2010)
MPI-ESM-MR*	1.8°x1.8°, T63, L95	Stevens et al. (2013) Jungclaus et al. (2013)
NorESM1-M*	1.9°x 2.5°, L26	Iversen et al. (2013)

⁴⁸Acrónimo del término inglés Climate Data Operator.

3.4. Datos CMIP5

CAPÍTULO 4

Metodología



4.1. Métodos de Análisis Estadísticos

En este capítulo se presentan los métodos utilizados para el desarrollo de la investigación. El capítulo se ha estructurado de la siguiente manera: los métodos estadísticos para la obtención y análisis de resultados (sección 4.1). Por otra parte, los métodos para la representación de los resultados obtenidos (sección 4.2) y la descripción del modelo agrícola basado en procesos utilizado en esta tesis doctoral (sección 4.3), “The general large-area model (GLAM) for annual crops”. Finalmente, se incluye el procedimiento para comparar la incertidumbre de las proyecciones que se obtienen con los diferentes modelos (sección 4.4).

4.1. Métodos de Análisis Estadísticos

4.1.1. Descomposición Empírica en modos por conjuntos

La descomposición empírica en modos por conjuntos (EEMD) (Huang & Wu 2008, Wu & Huang 2009) es una variante del método descomposición empírica en modos (EMD¹), desarrollado por Norden Huang (Huang et al. 1998, 1999, Huang & Wu 2008). Es un método adaptativo para el análisis de señales no lineales y no estacionarias. Este método hace hincapié en la capacidad de adaptación y localización temporal de la descomposición de datos. Los métodos más tradicionales de descomposición, como el método de Fourier o la descomposición wavelet, determinan previamente unas funciones básicas que pueden representar las características de una serie temporal, pero no en las series no estacionarias (Härdle 1990, Fan & Yao 2005). Otros métodos, incluyendo los métodos de descomposición empírica, dependen en gran medida de la autocorrelación, conteniendo implícitamente los dominios temporales. Por lo tanto, al aplicar estos métodos no se puede extraer el significado físico de las series no estacionarias. Por el contrario, EMD permite expresar una señal como una suma de componentes oscilatorias moduladas en amplitud/frecuencia. Cada una de estas componentes son conocidas como funciones de modo intrínsecas o modos, que representan procesos subyacentes en la señal. Sin embargo, en ciertos casos se presentan oscilaciones de amplitudes muy dispar de uno o más modos, u oscilaciones muy similares en diferentes modos, este fenómeno no deseado es conocido como “mezcla de modos” (Colominas et al. 2014). Para

¹Acrónimo del término inglés Empirical Mode Decomposition.

mermar este problema se propuso el método de descomposición empírica en modos por conjuntos (Wu & Huang 2009). EEMD realiza una descomposición empírica en modos sobre realizaciones de ruido blanco gaussiano sumadas a la señal de interés. El hecho de añadir ruido blanco a la señal reduce el problema de la mezcla de los modos al llenar por completo el espacio tiempo-frecuencia.

EMD descompone una señal (serie temporal) en Funciones de Modo Intrínsecas (Intrinsic Mode Functions, IMFs) o modos:

$$x(t) = \sum_{j=1}^n c_j(t) + r_n(t) \quad (4.1)$$

$$c_j(t) = a_j(t) \cos\left(\int w_j(t) dt\right) \quad (4.2)$$

donde c_j son las IMFs² y r_n es el residuo de la señal. Las IMFs dependen de la señal y deben satisfacer dos condiciones: (i) el número de puntos extremos (máximos y mínimos) y el número de cruces por cero deben ser iguales o como máximo diferir en uno; y (ii) la media local de cada IMF, definida como el valor medio de las envolventes superior e inferior, debe ser nula. El proceso de descomposición puede describirse de la siguiente manera:

1. Localizar todos los extremos locales (la combinación de ambos máximos y mínimos) de $x(t)$ y conectar todos los máximos (mínimos) con un spline cúbico.
2. Obtener la diferencia entre las series de tiempo y la media de la envolvente superior e inferior para producir una nueva serie temporal $h(t)$.
3. Para la serie temporal $h(t)$, se repiten, tantas veces como sea necesario, los pasos (1) y (2) hasta que la envolvente superior e inferior sean simétricas alrededor de cero dentro de una cierta tolerancia. La $h(t)$ final representa la primera IMF ($c_j(t)$).
4. Restar $c_j(t)$ a la serie temporal original ($x(t)$) para producir un residuo $r(t)$ y repetir los pasos 1-3 hasta que el residuo se convierta en una función monótona o una función que sólo contiene un valor extremo, de la que no se pueden extraer más IMF.

De esta manera queda completado el proceso de descomposición. Es evidente que EMD no es un método de ajuste de curva donde la forma de la función

²Acrónimo del término inglés Intrinsic Mode Functions.

4.1. Métodos de Análisis Estadísticos

usada se determina con anterioridad. Además, se ha probado que el uso de una spline de orden superior, en lugar de una spline cúbica, no modificaría significativamente los resultados (Huang & Wu 2008).

Una vez la serie temporal es descompuesta en las diferentes IMFs, se pueden aplicar diferentes métodos para obtener las frecuencias instantáneas de las IMFs, que conducen a la representación de los datos. La transformada de Hilbert (Gabor 1946, Van der Pol 1946) se aplica para estimar la distribución Tiempo-Frecuencia-Energía, denominada Espectro de Hilbert (Huang et al. 1998), es decir, se aplica para calcular la parte imaginaria de una IMF y obtener la expresión compleja de una IMF de las que se puede obtener la amplitud y frecuencia instantánea. Para cualquier función $c_j(t)$, la transformada de Hilbert $y_j(t)$ se define como:

$$y_j(t) = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{c_j(\tau)}{t - \tau} d\tau \quad (4.3)$$

La transformada de Hilbert y la función $x(t)$, forman un par conjugado complejo, y por lo tanto es posible definir una función analítica:

$$z(t) = c_j(t) + iy_j(t) = a_j(t)e^{i\theta_j(t)} \quad (4.4)$$

donde $i = \sqrt{-1}$.

$$\begin{aligned} a_j(t) &= (c_j^2 + y_j^2)^{1/2} \\ \theta_j(t) &= \arctan \frac{y_j}{c_j} \end{aligned} \quad (4.5)$$

La variable $a_j(t)$ representa la amplitud instantánea y $\theta_j(t)$ es la función de fase instantánea. La frecuencia instantánea, única para un tiempo dado es:

$$w_j(t) = \frac{d\theta_j(t)}{dt} \quad (4.6)$$

De esta manera, las ecuaciones 4.1, 4.2, 4.5 y 4.6 constituyen la distribución Tiempo-Frecuencia-Energía de una serie temporal $x(t)$.

Los resultados tras aplicar EMD pueden ser inestables con respecto al ruido de los datos ya que el ruido puede alterar la distribución de los extremos, lo que conlleva a una falta de robustez en las IMFs obtenidas. Además, este inconveniente dificulta la interpretación física de las IMFs. Para disminuir estos problemas, se desarrolló EEMD (Wu & Huang 2009). Como se ha mencionado

anteriormente, en este método se añaden múltiples realizaciones de ruido a la serie temporal $x(t)$. EEMD define a los modos como el promedio de las IMFs obtenidas con EMD sobre un conjunto de series temporales generadas al sumar diferentes realizaciones de ruido de varianza finita a la serie temporal original. De esta manera, se podrán extraer señales consistentes de las IMFs. El procedimiento de EEMD es el siguiente:

1. Se le añade una serie temporal de ruido blanco gaussiano a la serie original.
2. La serie con la señal de ruido ya incluida, se descompone aplicando EMD, obteniendo así las IMFs.
3. Se repiten los pasos (1) y (2), con diferentes series de ruido blanco hasta alcanzar un criterio de detención predefinido.
4. Obtener la media de las respectivas IMFs de las descomposiciones como el resultado final.

De esta forma, la señal de ruido blanco añadido se anula entre sí y la media de las IMFs se mantienen dentro de las diádicas naturales (Flandrin et al. 2004, Wu & Huang 2004, 2005). Por lo tanto, el método EMD/EEMD es mucho más robusto, eliminando muchos de los efectos secundarios debidos a la mezcla de escalas no físicas producidas por la presencia de ruido en los datos.

El método EMD ha sido aplicado con éxito en diferentes campos de la ciencia e ingeniería (Echeverría et al. 2001, Franzke 2009, Carmona & Poveda 2012, Capparelli et al. 2013) y ha sido citado más de 1000 veces (Wu et al. 2011), sin embargo, en el campo de las ciencias atmosféricas ha sido aceptado recientemente. Wu et al. (2007) aplicó EMD a la media anual de la temperatura media global en superficie. Guan (2014) aplicó EEMD para separar la tendencia de la variabilidad natural en el análisis de las respuestas fenológicas al calentamiento. Además, EEMD ha sido aplicado a las medias mensuales de la temperatura media global en superficie (Wu et al. 2011), a la temperatura del aire en superficie (Capparelli et al. 2013, Ji et al. 2014) y a la temperatura superficial del mar (Feng et al. 2014). Incluso, se ha aplicado en el campo de la agricultura para eliminar la tendencia del rendimiento de trigo observado en España (Hernández-Barrera et al. 2016, 2017).

En esta tesis doctoral, EEMD ha sido aplicado como un filtro de paso alta para retener todas las IMFs excepto el residual de las series temporales del

4.1. Métodos de Análisis Estadísticos

rendimiento de trigo observado, en otras palabras, se ha aplicado para separar la componente de tendencia del rendimiento del trigo observado (ver Capítulo 5) y a su vez, obtener sus escalas de variabilidad. Además, EEMD se utiliza para representar la componente de tendencia del rendimiento de trigo simulado a partir de los modelos CMIP5. Para realizar un estudio más completo que el de las de componentes de tendencia, se aplica el estimador de Sen (ver subsección a) para comparar las tendencias a lo largo de los siglos XX y XXI, y el test de Mann-Kendall para medir su significación (ver subsección b). En nuestro caso, aplicamos el paquete EMD/EEMD de Matlab de Flandrin et al. (2004).

En la Figura 4.1 y la Figura 4.2 se muestra un ejemplo de descomposición de la serie del rendimiento de trigo observado y de la serie del rendimiento de trigo del multimodelo simulado con los modelos CMIP5, respectivamente. La última IMF corresponde con la tendencia de cada serie.

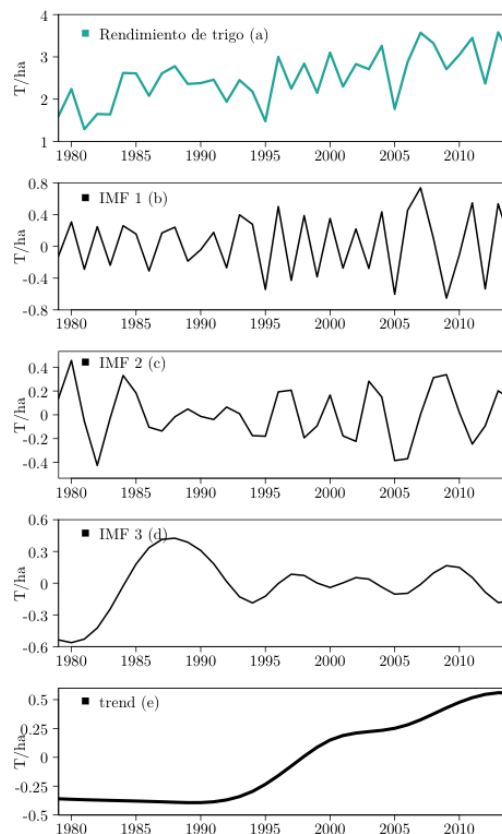


Figura 4.1: Serie temporal del rendimiento del trigo observado (a) y de las funciones de modo intrínseco (IMFs) (b-e), la última IMF corresponde con la tendencia

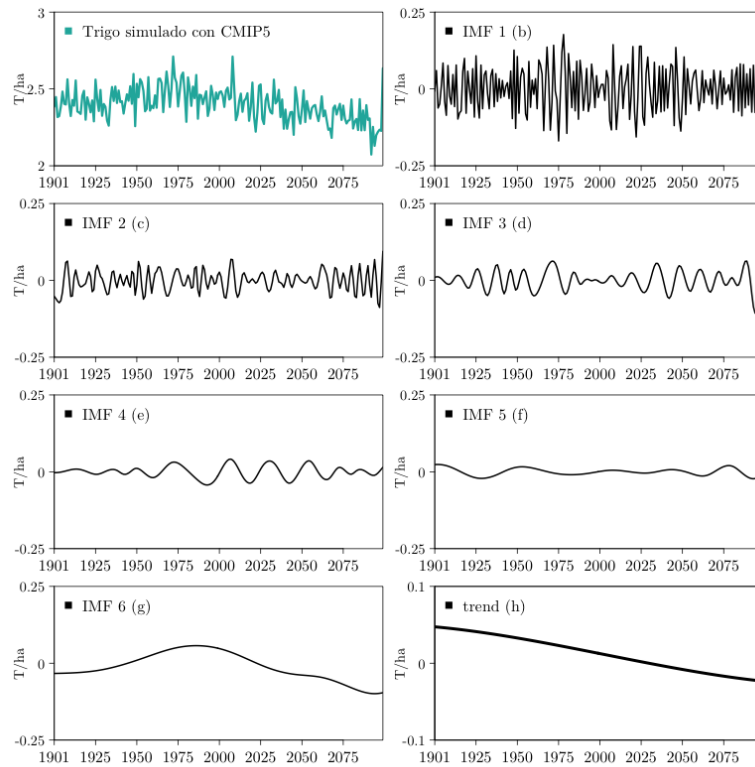


Figura 4.2: Serie temporal de: trigo simulado (a) y las funciones de modo intrínseco (IMFs) (b-h), la última IMF corresponde con la tendencia

a) Estimador de la pendiente de Sen

El estimador de Sen es una alternativa no paramétrica a la regresión lineal por mínimos cuadrados. Este método fue analizado por Sen (1968) e ilustrado por Gilbert (1987). El estimador de la pendiente de Sen es popular en las ciencias de la tierra (meteorología, climatología, hidrología y ecología) para medir fenómenos a lo largo del tiempo, tales como la calidad del aire y del agua y el retroceso glaciar. Se basa en la estimación de la pendiente de una línea, en otras palabras, cuantifica la tendencia de una serie como un cambio por unidad de tiempo t_1, t_2, \dots, t_n . Las ventajas de este método frente a otro es que permite la ausencia de valores o que la muestra no se ajuste a una distribución en particular. El procedimiento para la obtención de la pendiente se describe a continuación.

Primero se calculan todas las pendientes considerando los pares de datos mediante la siguiente fórmula:

4.1. Métodos de Análisis Estadísticos

$$Q_i = \frac{x_j - x_k}{t_j - t_k} \quad (4.7)$$

donde x_j y x_k son los valores de los datos de la serie temporal para los tiempos t_j y t_k , siendo $j > k$. Si hay n valores en la serie temporal habrá tantos como $N = \frac{n(n-1)}{2}$ pendientes estimadas Q_i .

Una vez obtenido todos los N valores Q de la pendiente, se ordenan de menor a mayor $Q_1 \leq Q_2 \leq \dots \leq Q_N$. La mediana de los N valores es el estimador de la pendiente de Sen, que se obtiene como:

$$Q_{med} = \begin{cases} Q_{\frac{N+1}{2}} & \text{si } N \text{ es impar} \\ \frac{Q_{\frac{N}{2}} + Q_{\frac{N+2}{2}}}{2} & \text{si } N \text{ es par} \end{cases} \quad (4.8)$$

donde el valor Q_{med} nos indica la pendiente de la línea de tendencia y su signo nos determina si la pendiente es positiva o no. La significación de la tendencia viene dada por el test Mann-Kendall, que se especifica en el siguiente apartado.

En esta investigación, el estimador de la pendiente de Sen se aplica para obtener la tendencia del trigo observado. Asimismo, para analizar la tendencia del rendimiento trigo a lo largo de un período histórico (1901-2000) y para predecir la tendencia del trigo a lo largo del siglo XXI (2001-2099).

b) Test de Mann-Kendall

El propósito del test de Mann-Kendall (MK³; Mann 1945, Kendall 1975) es evaluar estadísticamente si la serie temporal de una variable presenta una tendencia creciente o decreciente de forma monótona. Una tendencia creciente (decreciente) de forma monótona significa que la variable aumenta (disminuye) a lo largo del tiempo, sin importar si la tendencia es lineal o no. Este test presenta la ventaja de que es un test no-paramétrico, lo que quiere decir que los datos no requieren una distribución normal.

Según este test, la hipótesis nula H_0 asume que no existe una tendencia monótona en los datos, es decir, los datos son independientes y están ordenados al azar, y por el contrario la hipótesis alternativa H_a acepta que los datos presenten una tendencia monótona.

El test de MK evalúa los valores de los datos como una serie temporal donde cada dato es comparado con todos los datos posteriores. El valor inicial del estadístico MK, S , se supone que es 0, es decir, que no existe tendencia. Si

³Siglas del nombre Mann-Kendall.

un valor de la serie temporal es mayor que el valor anterior, S se incrementará en 1. Por otro lado, si el valor de la muestra es menor que el valor anterior, S disminuirá en 1. El resultado neto de diferencias positivas menos el número de diferencias negativas viene dado por S :

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sign}(x_j - x_i) \quad (4.9)$$

donde n representa la longitud de la serie temporal, x_j son cada uno de los valores de la serie temporal de los datos y

$$\text{sign}(x_j - x_i) = \begin{cases} 1 & \text{si } x_j - x_i > 0 \\ 0 & \text{si } x_j - x_i = 0 \\ -1 & \text{si } x_j - x_i < 0 \end{cases} \quad (4.10)$$

Cuando la longitud de la serie es $n \geq 10$, el estadístico S está aproximadamente distribuido de forma normal, donde su media es cero y su varianza se define como:

$$\sigma^2 = \frac{n(n-1)(2n+5) - \sum_{i=1}^n t_i(i-1)(2i+5)}{18} \quad (4.11)$$

donde t_i es el número de veces que se repite el dato i en la serie temporal. Una vez realizados los cálculos anteriores, el estadístico del test MK, Z se calcula mediante la siguiente fórmula:

$$Z = \begin{cases} \frac{S-1}{\sqrt{V(S)}} & \text{si } S > 0 \\ 0 & \text{si } S = 0 \\ \frac{S+1}{\sqrt{V(S)}} & \text{si } S < 0 \end{cases} \quad (4.12)$$

El estadístico Z es utilizado para evaluar la significación de la tendencia: un valor positivo (negativo) de Z indican una tendencia creciente (decreciente) de la serie temporal estudiada. Además, se utiliza para evaluar la hipótesis nula, H_0 . Si, $|Z| \geq Z_{1-\frac{\alpha}{2}}$ donde α representa el nivel de significación elegido, entonces la hipótesis nula no es válida, lo que implica que la tendencia es significativa.

El estadístico MK se utiliza en esta investigación para evaluar la significación de las tendencias, se aplica el test MK modificado según Yue y Wang (2004) teniendo en cuenta el efecto de la autocorrelación. Además, hemos considerado un nivel de significación $\alpha = 0,05$ donde los valores $1 - \frac{\alpha}{2} = 0,975$ y $Z_{1-\frac{\alpha}{2}} = 1,960$ por lo que una tendencia se considera significativa cuando

4.1. Métodos de Análisis Estadísticos

$$|Z| \geq 1,96.$$

4.1.2. Análisis de conglomerados de K-medias

El análisis de conglomerado de K-medias (K-means) es un método de agrupamiento desarrollado por MacQueen en 1967. Tiene como objetivo clasificar un determinado conjunto de datos en k grupos en los que cada grupo se determina por el grado de similitud entre ellos y la diferencia entre los objetos que pertenecen a otros grupos. K-means representa a cada uno de los grupos por la media (o media ponderada) de sus puntos, es decir, por su centroide. La ventaja de realizar la representación mediante centroides es que tienen un significado gráfico y estadístico inmediato. Cada grupo, por tanto, es caracterizado por su centro o centroide que se encuentra en el centro de los elementos que componen dicho grupo.

El objetivo del análisis de conglomerado de K-medias es minimizar la distancia euclídea al cuadrado entre los miembros de un grupo determinado y maximizar la distancia entre los centroides de los diferentes grupos (Wilks 2006), que se obtiene minimizando la varianza total de los grupos como la suma del error cuadrático:

$$J = \sum_{j=1}^k \sum_{i=1}^n \|x_i^{(j)} - c_j\|^2 \quad (4.13)$$

donde k es el número de grupos, n es el número de datos y $\|x_i^{(j)} - c_j\|^2$ es la distancia entre un dato y el centro del grupo. El procedimiento de agrupamiento es el siguiente:

1. Agrupar los datos en k grupos donde k debe ser predefinido.
2. Seleccionar k puntos como los centros de los grupos.
3. Asignar cada objeto a su grupo más cercano según la función de distancia Euclídea.
4. Recalcular el centroide o la media de todos los objetos en cada grupo y repetir los pasos 2-4 hasta que los mismos puntos se asignan a cada grupo.

K-means no es siempre un método eficiente debido a que, además del hecho de que sea necesario realizar en sucesivas ocasiones el procedimiento de

agrupamiento para tener el mejor resultado posible, el número óptimo de los grupos k debe ser seleccionado de antemano. Para solventar este problema, en esta investigación se comparan los resultados de múltiples ejecuciones con diferentes k y ruido aleatorio generado a partir de los datos iniciales con el fin de obtener la mejor división de los datos. Para ello, se aplica el criterio de la silueta (Rousseeuw 1987) con el que se determina el número óptimo de las agrupaciones k , que se explica en el siguiente apartado.

El método de conglomerado de K-medias se ha aplicado para realizar clasificaciones agroclimáticas, entre otras. Yang et al. (2006) hicieron una clasificación del rendimiento en combinación con la topografía y las características del suelo. En España, Iglesias et al. (2000) aplicaron el análisis de conglomerado para agrupar España en regiones agroclimáticas basados en datos de precipitación y temperatura. A diferencia de ellos, en esta tesis doctoral, se aplica el análisis de conglomerado de K-medias para agrupar los datos del rendimiento del trigo en regiones, debido a los diferentes comportamientos que presenta el rendimiento del trigo en las 48 provincias de toda España. Los resultados se muestran en el Capítulo 5.

a) Siluetas de los conglomerados

Las siluetas de los conglomerados es un método de interpretación y validación dentro de los análisis de conglomerado. Fue descrito por primera vez por Peter J. Rousseeuw en 1987. La técnica muestra una representación gráfica sucinta de lo bien que cada objeto se encuentra dentro de su grupo y cuales tienen una posición intermedia, mediante un diagrama de barras horizontales. Los rangos de la silueta varían desde -1 a 1 , donde un valor alto indica que el objeto está bien adaptado en su grupo, existiendo una buena separación entre los grupos restantes. Si la mayoría de los objetos de un grupo tienen un valor alto, entonces la configuración del agrupamiento es la apropiada. Si los objetos tienen valores negativos o bajos, entonces la configuración de agrupamiento puede tener demasiados o pocos grupos.

En esta investigación, el número óptimo de grupos (K) en los que debe ser clasificado el rendimiento del trigo se determina aplicando el criterio de la Silueta (ver Capítulo 5, sección 5.2).

4.1. Métodos de Análisis Estadísticos

4.1.3. Regresión de Mínimos Cuadrados Parciales

La regresión por mínimos cuadrados parciales o regresión PLS es un método que combina aspectos del análisis de Funciones Empíricas Ortogonales (EOF), también conocido como Análisis de Componentes Principales (PCA) y de la regresión lineal múltiple. La esencia de esta técnica, es encontrar una función lineal que describa el comportamiento de las variables dependientes (Y) en función de las variables independientes (X , predictores), solventando el problema de multicolinealidad y reduciendo el espacio de las variables independientes. La regresión puede ser univariada o multivariada.

- ◇ La regresión univariada considera una única variable dependiente (y):

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n \quad (4.14)$$

donde y es la variable dependiente; x_i son las variables independientes con $i = 1, \dots, n$ y b_i son los coeficientes de regresión de cada una de las variables x_i , donde b_0 es el coeficiente de regresión de la intersección con la ordenada en el origen.

- ◇ La regresión multivariada considera varias variables dependientes. En este caso, la representación es matricial:

$$Y = \beta X + \epsilon \quad (4.15)$$

donde Y es la matriz de las variables dependientes; X es la matriz de las variables independientes; β son los coeficientes de regresión; ϵ es la matriz que contiene los errores asociados a la regresión.

La regresión lineal múltiple sirve de base para diferentes métodos estadísticos multivariados, tales como, análisis discriminantes, regresión con componentes principales o análisis de correlaciones canónica. Estos métodos se caracterizan porque las componentes subyacentes a las variables X e Y nunca se extraen de matrices producto que involucren ambas variables. Por ejemplo, el método PCA busca estructuras en X que sean relevantes en X . Además, el número de combinaciones lineales posibles de X para predecir Y no puede exceder el número mínimo de las variables X e Y . Sin embargo, la regresión PLS

busca estructuras en X que son relevantes en Y , excediéndose, normalmente, del número máximo de variables X e Y .

El método de regresión PLS aparece por primera vez en el campo de Ciencias sociales, concretamente en el campo de Econometría, de la mano de Wold (1966). En las últimas décadas, se ha utilizado ampliamente en el campo de la Quimiometría (Wold 2001), al igual que en estudios por imágenes neuronales (McIntosh & Lobaugh 2004), en estudios de imágenes por resonancia magnética funcional (Worsley 1997) y en Biología Computacional (Tan et al. 2004) entre otros. En el campo de Ciencias de la Tierra, este método fue aplicado para la reconstrucción paleoclimática (Kalela-Brundin 1999), la predicción climática estadística (Woodcock & Engel 2005, McIntosh et al. 2005), la conexión atmósfera-océano (Smoliak et al. 2010, 2015), para realizar ajustes dinámicos (Wallace et al. 2012, Deser et al. 2014) y para evaluar las teleconexiones en la región Euro-Atlántica (González-Reviriego et al. 2015). Recientemente, la regresión PLS se ha aplicado en el campo de la Agricultura con el propósito de seleccionar las variables climáticas asociadas con las producciones de diferentes cultivos (Ceglar et al. 2016, Leng et al. 2016, Hernández-Barrera et al. 2016, 2017).

La regresión PLS es una herramienta estadística que se utiliza para modelizar la relación existente entre conjuntos de variables a partir de unas nuevas variables denominadas variables latentes y reducir su dimensionalidad. Este método es muy útil cuando el número de variables independientes es grande y muchas presentan multicolinealidad, es decir, que están altamente correlacionadas unas con otras y por lo tanto, no son linealmente independientes entre sí (Tobias 1995). Para mitigar el problema de multicolinealidad se impone la restricción de ortogonalidad sobre las variables latentes, y así reducir el número de variables independientes necesarias para describir las variaciones de los datos dependientes. Además, este método selecciona el subconjunto óptimo de los predictores, cosa que no se puede garantizar cuando se aplica la regresión por componentes principales (Abdi 2010).

En líneas generales y basándonos en la bibliografía de Abdi (2010), el objetivo de la regresión PLS es predecir una o más variables dependientes (Y) a partir de un conjunto de variables independientes (X) y describir su estructura común, es decir, la regresión PLS encuentra las componentes de X que mejor predicen Y . Este método descompone de forma simultánea las variables X e Y como el producto de un conjunto de factores ortogonales y un conjunto de pesos. Entonces X se descompone como:

4.1. Métodos de Análisis Estadísticos

$$X = TP^T \quad \text{tal que} \quad \overline{T^T T} = 1 \quad (4.16)$$

T es la matriz “scores” donde sus columnas son consideradas como los predictores, además son ortogonales entre sí. P es la matriz “loading” que contiene las estructuras asociadas a las variables independientes. De la misma manera Y es estimada como:

$$X = TBC^T \quad (4.17)$$

donde B es una matriz diagonal que contiene los pesos de la regresión, C es la matriz de pesos y las columnas de T son los vectores latentes. Los vectores latentes pueden ser seleccionados de diferentes maneras. En la regresión PLS son seleccionados a partir de dos conjuntos de pesos, w y c , que crean una combinación lineal de X e Y tal que su covarianza es máxima. El objetivo es obtener un par de vectores:

$$t = Xw \quad (4.18)$$

$$u = Yc \quad (4.19)$$

que satisfagan tres requisitos:

$$w^T w = 1 \quad (4.20)$$

$$t^T t = 1 \quad (4.21)$$

$$t^T u = \max \quad (4.22)$$

Los pesos relacionados con la variable independiente (w) son idénticos en forma a la matriz “loading” (P) con la diferencia que los primeros están normalizados. Cuando se cumplan los tres requisitos definidos previamente, el predictor t_i es eliminado de X e Y mediante una regresión de mínimos cuadrados ordinaria. Este proceso se repite hasta que X se convierta en una matriz nula. Una vez finalizado este procedimiento, los predictores se reordenan según la fracción de varianza contenida en cada componente, que explica la variable dependiente. Uno de los principales problemas que se presenta al aplicar la regresión PLS es determinar el número de componentes o variables latentes que se quieren incluir en la regresión, aunque se pueden incluir tantas componentes como el rango de la matriz de X . Habitualmente no se suelen utilizar todas, ya que si el número de componentes es inferior se puede minimizar el error

asociado a la regresión. Sin embargo, se pueden determinar a partir del cálculo del error cuadrático medio de predicción o mediante una validación cruzada, entre otros.

Para la implementación del método PLS (Wold et al. 1984, Naes & Martens 1985, Lorber & Kowalski 1988, Lindgren et al. 1993), existen diversos algoritmos. Los algoritmos más conocidos e utilizados son el algoritmo de NIPALS (Geladi & Kowalski 1986) y el algoritmo de SIMPLS (de Jong 1993), siendo NIPALS⁴ la versión más clásica del PLS. La principal diferencia que existe entre ambos es que el algoritmo de NIPALS aplica el proceso de deflación matricial sobre las X_0 e Y_0 y SIMPLS⁵ lo aplica sobre la matriz producto de X_0 y Y_0 , donde X_0 y Y_0 son las variables independientes y dependientes, respectivamente, después de restarle la media espacial. Además, el algoritmo de SIMPLS presenta algunas ventajas sobre el algoritmo NIPALS. En esta tesis doctoral, se utiliza el algoritmo de SIMPLS implementado en el paquete ‘pls’ del software R y en el paquete estadístico del software MATLAB. SIMPLS calcula directamente las componentes a partir de los datos originales centrados, y la matriz de pesos puede ser calculada sin hacer cálculos de matrices invertidas, por lo que su interpretación es más sencilla que la de la matriz de pesos obtenida con NIPALS. El algoritmo SIMPLS se puede resumir de la siguiente manera:

1. Se centran las variables X, Y por columnas, restando a cada una su valor medio:

$$X_0 = x_{0i} - \text{mean}(x_{0i}) \quad (4.23)$$

$$Y_0 = y_{0i} - \text{mean}(y_{0i}) \quad (4.24)$$

2. Se calcula la matriz de covarianza (S) como:

$$S = X_0' * Y_0 \quad (4.25)$$

3. Se descompone la matriz de covarianza en valores singulares:

$$SVD(S) \quad (4.26)$$

y se selecciona el primer vector singular por la izquierda (R).

⁴Acrónimo del término inglés Non-linear Iterative Partial Least Squares.

⁵Acrónimo del término inglés Straightforward Implementation of a statistically inspired Modification of the PLS.

4.1. Métodos de Análisis Estadísticos

4. Mediante la regresión del vector singular se obtiene la primera componente (X-score, T):

$$T = X_0 * R \quad (4.27)$$

5. La componente X-score se proyecta para obtener los X-loadings (P), Y-loadings (Q) e Y-scores (U):

$$P = X_0' * T \quad (4.28)$$

$$Q = Y_0' * T \quad (4.29)$$

$$U = Y_0 * Q \quad (4.30)$$

6. A partir de la matriz de covarianza y de la componente X-loadings, se calcula la matriz de covarianza residual:

$$S_{res} = S - P(P' * P)^{-1} * P' * S \quad (4.31)$$

7. Se repiten los pasos 3-6 utilizando la matriz de covarianza residual (S_{res}) para obtener una nueva componente que es ortogonal a la obtenida previamente. Este proceso se repite tantas veces como sea necesario, hasta que las sucesivas componentes no sean capaces de explicar la varianza en Y .

8. Por último, se obtienen los coeficientes de regresión (B) a partir de los pesos de una ecuación de regresión de Y en X a través de las componentes:

$$B = R * Q' \quad (4.32)$$

En líneas generales, la regresión PLS se aplica en esta investigación de dos maneras diferentes: en modo temporal y en modo espacial, que se representa gráficamente con un diagrama esquemático en la Figura 4.3. En dicho diagrama Y y Z representan las variables dependientes, y X y X' representan las variables independientes. En el modo temporal, la regresión PLS se aplica para obtener los modos estadísticos de las variables climáticas asociados con el rendimiento de trigo correspondiente al período de observación. En el modo espacial, la regresión PLS se aplica para derivar la variabilidad de estos modos conjuntamente con los datos CMIP5 (González-Reviriego et al. 2015) (ver Capítulo 5).




Figura 4.3: Representación gráfica de la regresión PLS en el modo temporal (a) y en el modo espacial (b). Cada caja representa una matriz con las dimensiones especificada en el margen izquierdo y superior. Y y Z son las variables dependientes, X y X' son las variables independientes

Por un lado, la regresión PLS produce los patrones espaciales de las variables climáticas asociadas con el rendimiento de trigo y las series temporales, es decir, las componentes PLS que indican la evolución temporal de dichos patrones. En este caso, las variables climáticas son las variables independientes y el rendimiento de trigo observado es la variable dependiente. Las variables independientes varían en el tiempo y en el espacio ($X(T,M)$) y la variable dependiente sólo varía en el tiempo ($Y(T)$). Por lo tanto, los patrones espaciales obtenidos ($Z(M)$) contienen los vectores latentes y son utilizados en la regresión PLS en el modo espacial y las componentes del PLS ($B(T)$) son utilizadas para determinar los modelos empíricos.

Por otro lado, la regresión PLS se aplica para conocer el impacto del cambio climático en las producciones de trigo en España. En este caso, las variables dependientes son los patrones espaciales de las variables climáticas asociados con el rendimiento de trigo, obtenidos con el modo temporal de la regresión PLS explicados anteriormente, y las variables independientes son las simulaciones de CMIP5 ($X'(M,T)$). Las variables dependientes sólo varían espacialmente ($Z(M)$) y las variables independientes varían en el tiempo y en el espacio ($X'(M,T)$). En este caso, la regresión PLS proporciona las estructuras comunes de CMIP5 y las series temporales o componentes PLS asociadas a los patrones observados (González-Reviriego et al. 2015). En este caso, las series temporales ($B'(T)$) derivadas de la regresión se utilizan para proyectar el rendimiento del trigo bajo los escenarios del cambio climático.

4.1. Métodos de Análisis Estadísticos

4.1.4. Regresión lineal múltiple: Regresión Paso a Paso

La regresión lineal múltiple se aplica para determinar la relación que existe entre una variable dependiente (Y) y un conjunto de variables independientes (X_1, X_2, \dots, X_n). Dicho en otras palabras, nos permite establecer la relación y el grado de asociación entre una variable dependiente y sus variables explicativas. La ecuación del modelo de regresión lineal múltiple es la siguiente:

$$Y = a_1X_1 + a_2X_2 + \dots + a_nX_n + e \quad (4.33)$$

donde Y es la variable a predecir, a_1, a_2, \dots, a_n son los coeficientes del modelo a estimar y e es el residuo.

Uno de los métodos más utilizados en la regresión lineal múltiple es el método de regresión “paso a paso” (Wilks 2006) que, a grandes rasgos, consiste en elaborar sucesivos modelos de manera que sólo difieran en una variable e ir comparando los resultados de cada uno con el anterior. El procedimiento que se lleva a cabo se describe a continuación.

Primero se selecciona el regresor (variable independiente) de mayor correlación con la variable dependiente, y se define una ecuación de regresión simple con esa variable. A continuación, se construye una segunda ecuación de regresión añadiendo a la ecuación anterior otro regresor, en este caso se introduce el regresor que mayor variabilidad explicada contenga la ecuación anterior. Este proceso se repite hasta que se hayan introducido todos los regresores que aporten una contribución específica propia, y es en este momento cuando el procedimiento se termina. Cabe destacar, que en este proceso de elaboración del modelo, hay una continua reevaluación de los predictores introducidos en el modelo, de manera que si alguno de los regresores queda explicado por los restantes, el método lo elimina.

En esta tesis doctoral, el método de regresión paso a paso se aplica para determinar los modelos agroclimáticos empíricos. La regresión paso a paso selecciona los indicadores climáticos, obtenidos previamente con la regresión PLS (ver subsección anterior), que caracterizan la variabilidad del rendimiento del trigo en España. En este caso se utiliza el paquete estadístico stepwise regression del software MATLAB. Para demostrar la eficiencia de los modelos, así como su calidad, se utiliza el método de la validación cruzada y el método de bootstrap, respectivamente, que están especificados en las siguientes subsecciones. Además, se aplica el test de Durbin-Watson para analizar su propagación e independencia (ver subsubsección c).

a) Método de Validación Cruzada

La validación cruzada (CV⁶) es una mejora del método de retención (holdout method) y fue descrita por primera vez por Stone en 1978. Esta técnica se utiliza para estimar la precisión de los resultados de un análisis estadístico y garantizar que son significativamente diferentes. La validación cruzada se utiliza en estudios de predicción con el fin de estimar la precisión de los modelos. En líneas generales, la validación cruzada consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes particiones. Existen tres tipos de validación cruzada: validación cruzada de K iteraciones, validación cruzada aleatoria y validación cruzada dejando uno fuera. El procedimiento más utilizado es la validación cruzada dejando uno fuera, que es el procedimiento que se utiliza en esta investigación y se describe a continuación.

La validación cruzada dejando uno fuera (LOOCV⁷), que viene representado por el diagrama de la Figura 4.4, implica separar los datos de forma que para cada iteración tengamos un solo dato de prueba (predictando) y todo el resto de los datos (predictores) para el entrenamiento, repitiéndose tantas veces como datos (n) contenga la muestra (Wilks 2006).

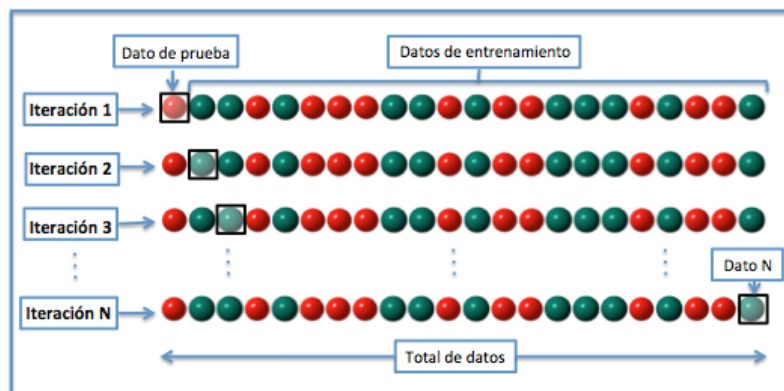


Figura 4.4: Diagrama de la validación cruzada dejando uno fuera. Figura obtenida de Wikipedia⁸

La evaluación de la validación cruzada viene dada por el promedio de los errores cuadráticos medio obtenido en cada iteración:

⁶ Acrónimo del término inglés Cross Validation

⁷ Acrónimo del término inglés Leave-One-Out Cross-Validation

⁸ https://es.wikipedia.org/wiki/Validaci%C3%B3n_cruzada

4.1. Métodos de Análisis Estadísticos

$$CV = \frac{1}{n} \sum_{i=1}^n MSE_i \quad (4.34)$$

$$MSE = (Y_i - \bar{Y}_i)^2 \quad (4.35)$$

donde n es el número de iteraciones, MSE_i es el error cuadrático medio de cada iteración e Y_i es el predictando de cada iteración. Este procedimiento presenta las ventajas de que la estimación del error no tiende a ser muy variable y además, no se tiende a sobreestimar el error.

En esta investigación se usa la validación cruzada para evaluar la incertidumbre de los modelos agroclimáticos empíricos y proporcionar así, el intervalo de confianza en la estimación de dichos modelos. También para proporcionar la varianza que describen los resultados predichos (R^2).

b) Método Bootstrap

El bootstrap o bootstrapping es un método de remuestreo propuesto por Bradley Efron en 1979 que permite solventar los problemas relacionados con la estimación de intervalos de confianza o la significación estadística. Este método se basa en generar muestras aleatorias con reemplazo a partir de un conjunto de datos de partida, donde cada una de las muestras debe tener el mismo tamaño que el conjunto de datos originales. De este modo, si el conjunto de datos originales tiene n elementos, las muestras generadas con la técnica bootstrap tendrá el mismo número de elementos que la muestra original y además, cada muestra podría incluir alguno de los datos originales más de una vez, ya que han sido elegidos de manera aleatoria de entre todo los elementos de los datos originales. Como resultado, cada muestra será, muy probablemente, algo diferente de la muestra original.

En esta investigación se utiliza la técnica bootstrap para obtener los coeficientes de correlación y el intervalo de confianza al 95 % de los modelos agroclimáticos empíricos obtenidos. En este caso el intervalo de confianza se obtiene, generando 500 muestras con reemplazo y cuantificando el intervalo de los coeficientes de correlación de las muestras. También se utiliza para generar mapas compuestos de variables climáticas correspondientes a valores extremos de la productividad de trigo.

c) Test de Durbin-Watson

El test de Durbin-Watson, propuesto por Durbin y Watson en 1950 y 1951, permite evaluar si existe autocorrelación entre los residuos de una regresión lineal múltiple. Este test pretende captar la dependencia de los valores en cuanto al orden de obtención. Si esto ocurriera se estaría incumpliendo algunas de las condiciones del modelo, por lo que los parámetros del modelo no cumplen los criterios de calidad que deberían. La hipótesis nula (H_0) de este test indica que los errores están serialmente correlacionados y con un proceso de primer orden autorregresivo, por el contrario, la hipótesis alternativa (H_a) indica que son aleatorios. Esta prueba estadística calcula la diferencia al cuadrado entre pares consecutivos de residuos divididos por un factor escala. Entonces la prueba estadística es:

$$DW = \frac{\sum_{i=2}^n (e_i - e_{i-1})^2}{\sum_{i=1}^n e_i^2} \quad (4.36)$$

donde i es el número de observaciones y e_i es el residual asociado a la observación en el tiempo i . Si el test de DW⁹ es relativamente pequeño, los residuos están correlacionados y tenderán a ser similares en magnitud. Si los residuos se distribuyen al azar, el numerador tenderá a ser mayor, por lo que se rechaza la hipótesis nula. Si DW presenta un valor alto, los residuos no están correlacionados, por lo tanto, los valores de los residuos serán muy diferentes el uno del otro.

En esta investigación se utiliza el test de Durbin-Watson para estimar la propagación y la independencia de los modelos agroclimáticos empíricos.

4.1.5. Corrección de sesgos en percentiles o empirical quantile mapping

De entre los diferentes métodos de corrección de sesgo, empirical quantile mapping (eQM) es uno de los más populares, consiste en calibrar la Función de Distribución Acumulativa simulada (CDF¹⁰) ó añadiendo a los cuantiles observados tanto la media de la fluctuación delta como las fluctuaciones deltas independientes en los correspondientes cuantiles. Además, este método se

⁹Siglas del nombre Durbin-Watson.

¹⁰Acrónimo del término inglés Cumulative Distribution Function

4.2. Métodos de Análisis Gráficos

puede aplicar a cualquier tipo de variable.

En esta tesis doctoral eQM se ha aplicado siguiendo el mismo procedimiento que Déqué (2007), se basa en corregir los percentiles 99 y la función de distribución acumulativa observada, utilizando la interpolación lineal para los valores entre dos percentiles:

$$q_m^* = F_0^{-1}(F_m(q_m)) \quad (4.37)$$

donde q_m^* y q_m corresponde con los cuantiles corregidos y simulados, respectivamente. Se aplica una extrapolación constante para valores fuera del intervalo de calibración, es decir, la función de corrección del último percentil se aplica a todos los valores por encima del mismo.

El método eQM se ha aplicado para calibrar las simulaciones y proyecciones del rendimiento de trigo, ajustando la distribución de frecuencia del trigo simulado con respecto al observado. En el caso del rendimiento de trigo simulado en el período observacional, eQM se aplica al período 1980-1997, de modo que las correcciones de sesgo se extrapolan al período observacional restante, 1997-2014. Para las proyecciones del rendimiento de trigo, el período utilizado para el ajuste de frecuencia corresponde con el período observado (1980-2014) y se extrapola al rendimiento de trigo del período 2015-2099.

4.2. Métodos de Análisis Gráficos

4.2.1. Mapas de correlación

La asociación entre variables se va a mostrar por el coeficiente de correlación de Pearson, utilizando la transformación de Fisher Z (Fisher 1915) cuando las distribuciones no son Gaussianas. El coeficiente de correlación de Pearson se define como la raíz cuadrada del cociente entre la covarianza de las dos variables y el producto de las desviaciones estándar de ambas variables y se representa como r_{xy} :

$$r_{xy} = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{(n-1) \sigma_x \sigma_y} = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{n \sum x_i^2 - (\sum x_i)^2} \sqrt{n \sum y_i^2 - (\sum y_i)^2}} \quad (4.38)$$

El valor del índice de correlación varía en el intervalo $[-1,1]$, de manera que si $r_{xy} = -1$ ($r_{xy} = 1$) existe una asociación negativa (positiva) perfecta entre las variables.

Cuando se quiere obtener la correlación entre una serie temporal de un índice y las series temporales de las anomalías de muchos lugares geográficos. Lo que se hace es representar cada una de las correlaciones en el lugar geográfico para el que han sido obtenidas dando lugar a un mapa de correlación. Al igual que el coeficiente de correlación de Pearson, los mapas de correlación varían entre 1 y -1, donde los valores positivos (negativos) de una región geográfica indican que en dicha región existe una asociación positiva (negativa).

En esta investigación se muestran mapas de correlación con diferentes propósitos: primero, analizar el peso que tienen los rendimientos de trigo provinciales en la serie de rendimiento de trigo promediada en toda España; segundo, para obtener la influencia de distintas variables climáticas en los rendimientos de trigo provinciales; y tercero, para obtener la influencia de los modos de variación derivados de la regresión PLS en el rendimiento de trigo provincial. Para interpretar los mapas de correlación, estos se muestran con su significación que se calcula mediante el método Tasas de Falso Descubrimiento que considera el efecto de la multiplicidad espacial, es decir el efecto de la dependencia espacial.

a) Tasa de Falso Descubrimiento

Existen diferentes métodos que incorporan el efecto de la dependencia espacial a la hora de indicar la significación de un mapa de correlación. Algunos utilizan métodos de “resampling”, por ejemplo, Livezey & Chen (1983) lo utilizaron para determinar el valor de la correlación para un determinado nivel de significación. Otro método para abordar este problema se puede utilizar la tasa de falso descubrimiento (FDR), que fue descrito por primera vez por Benjamini & Hochberg en 1995, enfocado a la estadística médica. FDR¹¹ cuantifica la proporción de rechazos incorrectos entre todos los rechazos de la hipótesis nula que son realmente ciertos. Por lo tanto, FDR determina a partir de que p-value se puede considerar la hipótesis nula como cierta, por lo que se rechazaran algunas de las hipótesis nulas locales.

Según Wilks (2016) es necesario aplicar FDR para dar una correcta interpretación de los resultados obtenidos al utilizar métodos estadísticos en los que se realizan múltiples pruebas a la vez, como es el caso de los mapas de correlación entre otros. De esta manera se evitan las exageraciones y excesos en las interpretaciones de los resultados científicos. En esta investigación se utiliza FDR para dar una adecuada interpretación a aquellos mapas de correlación

¹¹Acrónimo del término inglés False Discovery Range.

4.2. Métodos de Análisis Gráficos

que fueron obtenidos con posterioridad a la publicación de Wilks (2016).

4.2.2. Diagramas de cajas

El diagrama de Cajas, también conocido como diagrama de Caja-Bigotes (Box-plot o box-and whisker plot), es una herramienta gráfica ampliamente utilizada e introducida por Tukey (1977). Este diagrama representa la distribución de datos mediante el valor mínimo (\mathbf{X}_{min}) y máximo (\mathbf{X}_{max}) de los datos y tres cuartiles: primer cuartil ($\mathbf{q}_{0,25}$), segundo cuartil ($\mathbf{q}_{0,5}$), que coincide con la mediana, y el tercer cuartil ($\mathbf{q}_{0,75}$) (Figura 4.5). Este diagrama viene representado por un rectángulo cuyos valores superiores e inferiores representan el primer y tercer cuartil de los datos, el intervalo comprendido entre ellos se denomina recorrido intercuartílico. El rectángulo está dividido por un segmento vertical que representa a la mediana y las líneas que sobresalen de la caja (bigotes) se extienden hasta los valores mínimos y máximos de los datos representados.

La interpretación de los diagramas de cajas es sencilla. La posición y el tamaño de la caja nos indican entre que valores se encuentran la mayoría de los datos de la distribución. La línea que divide la caja en dos partes corresponde con la mediana y nos indica la simetría/asimetría de la distribución. Si la mediana se encuentra situada a la mitad de la caja y los bigotes tienen una longitud similar, entonces se dice que la distribución es simétrica. Si no cumplen estas condiciones se dice que la distribución es asimétrica o sesgada.




Figura 4.5: Esquema de un diagrama de Cajas mostrando el valor mínimo, máximo y los cuartiles de un conjunto de datos: distribución simétrica (a) y distribución asimétrica (b)

El inconveniente del diagrama de Cajas es que no ofrece información de los valores atípicos, que son aquellos valores que se encuentran por encima (debajo) de los valores máximos (mínimos) de la muestra. El diagrama sólo muestra los valores máximos y mínimos con los bigotes, por lo que no se puede saber si los valores atípicos están aislados de la distribución o, por el contrario, todos los

datos están distribuidos homogéneamente en el diagrama. Este problema fue solventado por Tukey (1977), para ello modificó el diagrama de Caja y creó el que se conoce como diagrama Esquemático (Figura 4.6), que es idéntico al diagrama de Cajas, pero los valores atípicos se representan de forma individual con asteriscos o puntos. Se consideran valores atípicos si se encuentran entre:

$$\begin{aligned} q_{0,75} + \frac{3(q_{0,75} - q_{0,25})}{2} &\leq \text{valor atípico} \\ q_{0,25} - \frac{3(q_{0,75} - q_{0,25})}{2} &\geq \text{valor atípico} \end{aligned} \quad (4.39)$$

donde $(q_{0,75} - q_{0,25})$ es el rango intercuartílico.




Figura 4.6: Esquema de un diagrama Esquemático mostrando el valor mínimo, máximo, los cuartiles y los valores atípicos de un conjunto de datos

En esta investigación se han utilizado los diagramas Esquemáticos para obtener el cambio del rendimiento del trigo bajo el efecto del cambio climático. En este caso se compara las distribuciones de probabilidad del rendimiento de trigo observado con los rendimientos del trigo simulados a partir de los modelos CMIP5 y el multimodelo en diferentes períodos: un período de observación (1980-2014) y un periodo de proyección (2070-2099). Además, los diagramas se utilizan para estimar las distribuciones de probabilidad de los rendimientos del trigo simulados, obtenidos con el modelo GLAM, respecto a las observaciones. Cabe señalar que, aunque en esta tesis doctoral se utiliza el diagrama Esquemático, se empleará el término de diagrama de Cajas para referirnos al mismo ya que comúnmente se conoce con este nombre.

4.2.3. Diagramas de Taylor

El diagrama de Taylor (Taylor 2001) es un método para resumir gráficamente la similitud de varios modelos con respecto a uno de referencia. Con estos diagramas se puede resumir gráficamente cómo de semejantes son los modelos a la observación. La evaluación se cuantifica en términos de su corre-

4.2. Métodos de Análisis Gráficos

lación, sus desviaciones estándar y la diferencia centrada de la raíz cuadrada del error cuadrático medio (RMSE). Los estadísticos de cada modelo estarán representados por un punto en el diagrama y se calculan mediante las expresiones matemáticas que se especifican a continuación.

Considerando un campo de prueba (f) y un campo de referencia (r), el coeficiente de correlación R entre ambos campos se define como:

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})(r_i - \bar{r})}{\sigma_f \sigma_r} \quad (4.40)$$

donde \bar{f} y \bar{r} son las medias de cada campo y σ_f y σ_r son las desviaciones estándar de f y r , respectivamente, que se obtienen como:

$$\sigma_f = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2} \quad (4.41)$$

$$\sigma_r = \sqrt{\frac{1}{n} \sum_{i=1}^n (r_i - \bar{r})^2} \quad (4.42)$$

Y el RMSE¹², representado por la letra E , es definido mediante la siguiente expresión:

$$E = \sqrt{\frac{1}{n} \sum_{i=1}^n [(f_i - \bar{f}) - (r_i - \bar{r})]^2} \quad (4.43)$$

Además, todos estos estadísticos se pueden relacionar mediante la siguiente expresión:

$$E^2 = \sigma_f^2 \sigma_r^2 - 2\sigma_f \sigma_r R \quad (4.44)$$

Esta relación es la que hace posible que en cada punto en el espacio de dos dimensiones del diagrama de Taylor se pueda representar tres estadísticos simultáneamente.

En esta investigación se utiliza el diagrama de Taylor para evaluar las incertidumbres de las simulaciones de las variables climáticas obtenidas como salidas de los modelos CMIP5 y del multimodelo en el período de observación 1979-2014. En este caso, se evalúa la precipitación y temperatura en las diferentes estaciones con respecto a las observaciones de dichas variables. La

¹²Acrónimo del término inglés Root Mean Square Error.

posición de cada punto indica cómo de parecido son las temperatura y precipitación simuladas por los modelos y por el multimodelo, a las temperaturas y precipitaciones observadas de los datos E-OBS. En la Figura 4.7 se muestra, a modo de ejemplo, el diagrama de Taylor para la precipitación. Por otro lado, el diagrama de Taylor se aplica para analizar las incertidumbres de las simulaciones obtenidas con el modelo agrícola GLAM del rendimiento del trigo de 46 provincias y de las dos regiones en las que se clasifica el trigo en España, respecto a la serie histórica del rendimiento del trigo para toda España en el período 1997-2014. Al igual que en el caso anterior, la posición de cada punto indica el acuerdo entre las simulaciones del rendimiento del trigo al rendimiento de trigo observado. En ambos casos, las observaciones siempre se representan sobre el eje inferior del diagrama de Taylor, de esta manera las simulaciones que más se parezcan a las observaciones estarán próximas a las observaciones y tendrán un valor alto de correlación y un RMSE bajo.




Figura 4.7: Diagrama de Taylor para la precipitación obtenidas con los dos modelos CMIP5 y el multimodelo para el período 1979-2014. Los números indican el modelo, correspondiendo el número 13 con el multimodelo y el 14 con la observación, el cual se toma como referencia

4.3. Modelo agrícola: “The general large-area model (GLAM) for annual crops”

“The general large-area model (GLAM) for annual crops” es un modelo agrícola diseñado para evaluar los impactos de la variabilidad climática y el cambio en los cultivos. Además, se puede aplicar con datos procedentes de modelos climáticos globales y regionales, así como datos de teledetección. Challinor et al. (2004) lo utilizaron, por primera vez, para simular el rendimiento

4.3. Modelo agrícola: “The general large-area model (GLAM) for annual crops”

del cacahuete en la India con datos observados, datos de reanálisis (Challinor et al. 2005a), predicciones estaciones dinámicas (Challinor et al. 2005b) y simulaciones dinámicas del clima futuro (Challinor et al. 2005c, Challinor & Wheeler 2008). La primera versión de GLAM también se ha utilizado para simular el rendimiento del cacahuete en Gambia utilizando estimaciones de precipitación recabadas vía satélite (Chee-Kiat 2006). Además, ha sido incorporado en el programa de superficie del terreno del Grupo de trabajo de modelos acoplados (GCM; Osborne et al. 2007). GLAM se modifica para poder simular diferentes cultivos. Por ejemplo, Li (2008) y Challinor et al. (2010) desarrollaron la versión para el trigo, que fue utilizada para evaluar el impacto del cambio climático en las producciones de trigo de primera e invierno en China. Greatrex (2012) desarrolló una versión para el maíz con la que simuló los rendimientos del maíz en Etiopía utilizando estimaciones de precipitación recabadas vía satélite. Además, esta versión se ha utilizado para simular el rendimiento del maíz en Brasil utilizando a partir de datos observados (Bergamaschi et al. 2013). Osborne et al. (2013) utilizaron la versión del trigo y además, desarrollaron una versión para el rendimiento de la soja para evaluar los impactos del cambio climático en estos cultivos a escala global. Nicklin K. (2013) desarrolló una versión para el rendimiento de sorgo con el fin de anticipar las cosechas en África Occidental.

GLAM simula el balance hídrico del suelo, el crecimiento de las hojas y de las raíces del cultivo, la biomasa, así como el rendimiento del cultivo, que está limitado por YGP. Para ello, el modelo necesita datos climáticos, la fecha de la siembra y las propiedades hidrológicas del suelo que se consideran constantes con la profundidad. Los datos climáticos requeridos son datos diarios de precipitación, temperatura máxima y mínima y radiación solar en superficie.

En líneas generales, GLAM simula el rendimiento del cultivo como el producto de la biomasa acumulada y el índice de cosecha. La Figura 4.8 muestra un diagrama de la estructura de GLAM y los procesos llevados a cabo por el modelo. Los parámetros más importantes del modelo son la fecha de siembra y el parámetro YGP. La fecha de siembra depende del lugar. YGP es el parámetro que se utiliza para calibrar GLAM, que varía entre un rango de 0 a 1. El valor óptimo se elige minimizando la raíz cuadrada del error cuadrático medio (RMSE) entre los rendimientos observados y simulados. Si YGP es igual a 1 indica que el rendimiento simulado es igual al rendimiento potencial. Asimismo, el impacto de la concentración de CO_2 en el crecimiento y el rendimiento del cultivo no se modela directamente, sino que se simula a través de la eficiencia de la transpiración. De este modo, los principales resultados de GLAM son el

índice de superficie foliar (LAI), la profundidad de las raíces, la evapotranspiración real y potencial, el balance hídrico, la biomasa y el rendimiento del cultivo.

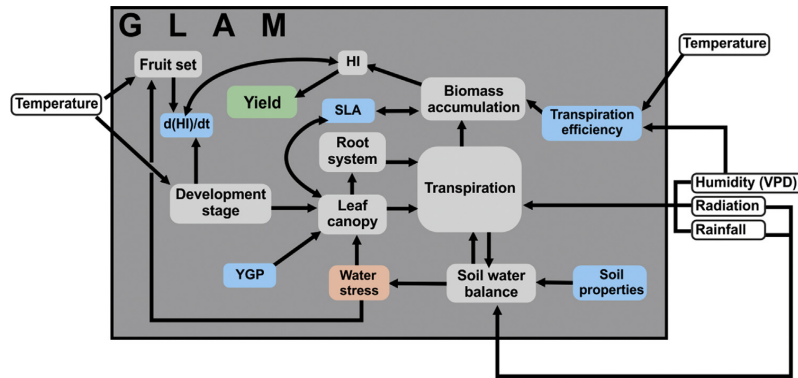


Figura 4.8: Diagrama esquemático que representa la estructura del modelo. Los rectángulos grises representan el estado de las variables, excepto el rendimiento que se muestra en verde, los rectángulos azules indican las constantes del modelo y los naranjas las variables intermedias. Las flechas muestran el flujo de información. Los valores diarios de la radiación, la temperatura, la precipitación y la humedad relativa (VPD) corresponden con las variables de entrada y se encuentran fuera del rectángulo principal. Figura obtenida del artículo Ramirez-Villegas et al. (2015)

A continuación, se detalla una breve descripción de la versión original de GLAM (Challinor et al. 2004), que se divide en dos partes: (a) el crecimiento y desarrollo del cultivo, (b) la evapotranspiración y el balance hídrico. No obstante, en Challinor et al. (2004) se puede encontrar una descripción más detallada de GLAM.

a) El crecimiento y desarrollo del cultivo

GLAM divide en 4 etapas el ciclo de vida del cultivo:

1. desde la siembra hasta la floración
2. desde la floración hasta el inicio de las vainas
3. desde el inicio de las vainas hasta que el crecimiento de las hojas sea máximo
4. desde el crecimiento de las hojas hasta la madurez

En cada etapa, GLAM determina qué partes de la planta crecen y qué partes de la planta pueden verse afectadas por el entorno.

4.3. Modelo agrícola: “The general large-area model (GLAM) for annual crops”

El tiempo térmico acumulado se define como la temperatura efectiva diaria (T_{eff}) excedida de la temperatura base (T_b) y se puede expresar como:

$$t_{TT} = \int_{t_i}^{t_{i+1}} (T_{eff} - T_b) dt \quad (4.45)$$

donde t es el tiempo, i es la etapa del desarrollo, t_{TT} es el tiempo térmico. La temperatura base es la temperatura por debajo de la cual el cultivo no se desarrolla.

La duración de cada etapa depende de la temperatura, es decir, cada etapa se completa cuando se acumula una cantidad de tiempo térmico. Por lo tanto, una vez que la acumulación del tiempo térmico (t_{TT}) alcanza un determinado valor finaliza una etapa y comienza la otra.

La superficie foliar del cultivo crece durante las tres primeras etapas del desarrollo hasta alcanzar su valor máximo y permanece constante en la cuarta etapa. La producción de la superficie foliar es simulada mediante el LAI¹³, que es la superficie foliar por m^2 de tierra cultivada, y está limitado por el factor de estrés hídrico (S) y por el YGP, bajo condiciones no óptimas. Puede representarse como:

$$\frac{\partial L}{\partial t} = \begin{cases} \left(\frac{\partial L}{\partial t}\right)_{max} C_{YGP} \min\left(\frac{S}{S_{cr}}, 1\right) & i < 3 \\ 0 & i = 4 \end{cases} \quad (4.46)$$

$$S = \frac{T_T}{T_{T_{opt}}} \quad (4.47)$$

donde L es LAI, $\left(\frac{\partial L}{\partial t}\right)_{max}$ es la tasa de incremento de LAI bajo condiciones óptimas, es el parámetro YGP y S es el factor hídrico de estrés, que se define como se muestra en la ecuación 4.47, es la relación entre la tasa de transpiración diaria (T_T) y la transpiración potencial $T_{T_{opt}}$. El crecimiento de las hojas está restringido por el estrés hídrico del suelo cuando cae por debajo de un umbral crítico S_{cr} .

El crecimiento de la raíz se utiliza para determinar la absorción de agua del suelo, que se describe mediante la densidad de longitud de la raíz (l_v) en cada capa del suelo. Dado que el crecimiento de la superficie foliar está limitado por el agua y el parámetro YGP, el crecimiento de la raíz también lo estará. El valor en la superficie ($z=0$) se incrementa linealmente con el índice de superficie foliar, alcanzando su valor máximo a la vez que lo alcanza la superficie de la

¹³ Acrónimo del término inglés Leaf Area Index.

hoja:

$$\left(\frac{\partial l_v(z=0)}{\partial L}\right) = \text{constante} \quad (4.48)$$

$$l_v(z = z_{ef}) = \text{constante} \quad (4.49)$$

La densidad de longitud de la raíz es linealmente interpolada entre la superficie y la parte delantera de la raíz (z_{ef}), que se mueve hacia abajo en el interior del suelo a una velocidad constante (V_{ef}).

En GLAM, la biomasa (W) se calcula multiplicando la transpiración por la eficiencia de la transpiración:

$$\frac{\partial W}{\partial t} = T_T \min\left(\frac{E_T}{V}, E_{TN,max}\right) \quad (4.50)$$

donde T_T es la transpiración, que está afectada por la temperatura, LAI, el crecimiento de la raíz y el agua disponible en el suelo. E_T es la eficiencia de la transpiración normalizada, $E_{TN,max}$ es la máxima eficiencia de la transpiración y V es el déficit de vapor, que depende de la temperatura.

Por lo tanto, el rendimiento del cultivo se define como el producto de la biomasa (W) y el índice de cosecha (H_I):

$$Y = H_I W \quad (4.51)$$

El índice de cosecha es cero durante las dos primeras etapas del desarrollo del cultivo y luego aumenta, de manera lineal, desde el inicio de las vainas hasta la madurez.

b) La evapotranspiración y el balance hídrico

La tasa de transpiración (T_T) y de evaporación (E) depende de la estructura planta/suelo y de la disponibilidad energética, además se tiene en cuenta las limitaciones del agua. La transpiración limitada fisiológicamente es una función del LAI y se calcula utilizando una ecuación empírica de Azam-Ali (1984):

$$T_{T_{pot}}^p = \begin{cases} T_{T_{max}} \left(1 - \frac{L_{cr}-L}{L_{cr}}\right) & \text{si } L < L_{cr} \\ T_{T_{max}} & \text{si } L \geq L_{cr} \end{cases} \quad (4.52)$$

donde L_{cr} es el valor crítico de L , todos los valores de L por debajo de este

4.3. Modelo agrícola: “The general large-area model (GLAM) for annual crops”

umbral limitan la transpiración, y $T_{T_{max}}$ es la tasa máxima de transpiración posible, que depende de la energía disponible.

La evapotranspiración potencial (E_{pot}^T) es la energía limitada de las tasas de evaporación y transpiración y se calcula utilizando la ecuación de Priestly-Taylor (Priestly & Taylor 1972):

$$E_{pot}^T = E^e + T_T^e = \frac{\alpha \Delta (R_N - G)}{\lambda \Delta + \gamma} \quad (4.53)$$

donde α es el coeficiente Priestly-Taylor, Δ es la derivada parcial de la presión de vapor saturada respecto a la temperatura, R_N es la radiación neta, G es el flujo térmico del suelo, λ es el calor latente de la vaporización del agua y γ es el calor específico del aire a presión constante dividido por el calor latente de la vaporización del agua. A continuación, se definen estos parámetros.

El coeficiente Priestly-Taylor se calcula a partir del déficit de presión de vapor (V):

$$\alpha = 1 + (\alpha_0 - 1) \frac{V}{V_{ref}} \quad (4.54)$$

donde V_{ref} y α_0 son constantes.

La radiación neta depende de la radiación de onda corta incidente (S_{rad}) y del albedo de la superficie (A):

$$R_N = (1 - A)S_{rad} \quad (4.55)$$

El flujo térmico del suelo viene dado por (Choudhury et al. 1987):

$$G = C_G R_N e^{-kL} \quad (4.56)$$

donde C_G es una constante y k es un coeficiente de extinción.

La energía limitada de las tasas de evaporación y transpiración es estimada con la ecuación Beer-Bourgert (Arya 1988):

$$E^e = (1 - C_G) E_{max}^T e^{-kL} \quad (4.57)$$

$$T_T^e = E_{max}^T (1 - e^{-kL}) \quad (4.58)$$

donde E_{max}^T es el máximo posible de energía de la evapotranspiración cuando $G=0$. Estas ecuaciones han sido adaptadas para cultivos específicos desde la publicación Challinor et al. (2004).

La evaporación y la transpiración potenciales diaria se definen como:

$$E_{pot} = \frac{E^e}{t_R} \quad (4.59)$$

$$T_{T_{pot}} = \min(T_{T_{pot}}^p, T_T^e) \quad (4.60)$$

donde t_R es el número de días cuando la precipitación diaria excede de 1 mm.

Entonces la transpiración y evaporación real se calculan de acuerdo con la disponibilidad de agua. Cuando el agua del suelo extraíble es suficiente, la evaporación y la transpiración son iguales a la evaporación y la transpiración potenciales (ecuación 4.61 y 4.62).

$$T = T_{pot} \quad (4.61)$$

$$E = E_{pot} \quad (4.62)$$

Sin embargo, cuando hay escasez de agua, el agua se comparte entre la transpiración y la evaporación, de acuerdo con la relación de la transpiración y la evaporación potenciales (ecuaciones 4.63 y 4.64).

$$T_T = \theta_{pe} \left(\frac{T_T^e}{T_T^e + E^e} \right) \quad (4.63)$$

$$E = \theta_{pe} \left(\frac{E^e}{T_T^e + E^e} \right) \quad (4.64)$$

θ_{pe} es el agua del suelo potencialmente extraíble y depende del tiempo, la longitud de la raíz y el agua disponible en el suelo. Se calcula mediante la parametrización de Passioura (1983):

$$\theta_{pe} = \int_0^{Z^{max}} \theta_{cr} (1 - e^{k_{DIF} l_v(z) t_e(Z)}) dz \quad (4.65)$$

donde $t_e(Z)$ corresponde con el tiempo de la primera absorción hecha por las raíces en la capa z y k_{DIF} es el coeficiente de difusión de absorción. Estas expresiones también han sido modificadas desde la publicación Challinor et al. (2004).

El balance hídrico del suelo se calcula en función de la infiltración de agua en el suelo debido a la precipitación, la evapotranspiración, la escorrentía y el drenaje:

4.3. Modelo agrícola: “The general large-area model (GLAM) for annual crops”

$$S_w = T_{rain} - T_{tran} - T_{evap} - T_{run} - T_{drain} \quad (4.66)$$

donde S_w es el agua neta de entrada al suelo, T_{rain} la precipitación total, T_{tran} la transpiración total, T_{evap} la evaporación total, T_{run} el total de escorrentía y T_{drain} el drenaje total. En GLAM, el balance hídrico del agua se calcula a partir del límite superior (v_{dul}) e inferior del drenaje (v_{rl}) y del límite de saturación del suelo (v_{sat}). Además, GLAM considera que la precipitación, sin escorrentía, pasa a través de la primera capa del suelo, entonces el agua filtrada se distribuye a lo largo de las diferentes capas en las que se divide el suelo (N_{SL}). Las ecuaciones que describen detalladamente el balance hídrico del agua de pueden encontrar en Challinor et al. (2004).

En las versiones posteriores de GLAM a la descrita en esta tesis doctoral, se han modificado algunos de estos parámetros y se han añadido nuevos parámetros, dependiendo del cultivo que se estudie. Incluso, James Watson, en la Universidad de Leeds, desarrolló el programa “GLAM optimiser” (Nicklin 2013), con el fin de seleccionar los valores óptimos de los parámetros de GLAM, a partir de un rango predefinido. Aunque los parámetros de GLAM se pueden obtener a partir de las observaciones, con la excepción YGP, pueden variar de un lugar a otro. De esta manera, “GLAM optimiser” da un rango realista del parámetro, en lugar de un valor definido.

“GLAM optimiser” ejecuta varias veces GLAM con distintos parámetros y obtiene unos nuevos parámetros que minimizan la raíz cuadrada del error cuadrático medio (RMSE) entre los rendimientos observados y simulados. El usuario debe indicar que parámetros deben variar y el rango de valores que pueden tomar. Entonces, el optimizador selecciona un parámetro al azar, ejecuta GLAM y recupera el RMSE. Este proceso se repite reiteradas veces para un solo parámetro, donde su nuevo valor se selecciona al azar y este es aceptado si el RMSE ha disminuido. El número de iteraciones, que es elegido por el usuario, debe de ser suficientemente grande para que el RMSE sea mínimo. En esta investigación, el número de iteraciones seleccionado es 5000, debido a que Nicklin (2013) demostró que 5000 iteraciones son suficientes para que RMSE sea pequeño.

En esta investigación, se utiliza “GLAM optimiser” y la versión de GLAM para el trigo de invierno (GLAM-trigo; Li 2008, Challinor et al. 2010). “GLAM optimiser” se utiliza para encontrar el conjunto de parámetros óptimos para cada región en la que el trigo de invierno de España fue clasificado según

su comportamiento, que se presentan en la Tabla 4.1. Estos parámetros han sido utilizados para calibrar GLAM y simular el rendimiento de trigo en cada región y en las 46 provincias de España, según a la región a la que pertenece. El período utilizado para la calibración va desde 1980 hasta 1996, y el período utilizado para la simulación es 1997-2014.

Los rendimientos de trigo simulados por GLAM se analizan mediante los siguientes procedimientos. En primer lugar, las simulaciones se evalúan con las observaciones para comprobar si el modelo es adecuado para responder a cuestiones de esta investigación, por ejemplo, estudiar la influencia de la variabilidad climática en el rendimiento del trigo y obtener el impacto del cambio climático en el rendimiento. Para ello se utilizan métodos gráficos y cuantitativos previamente indicados. Por otra parte, evaluamos la respuesta de los datos simulados a las variables climáticas. Para ello se procede con estos datos, como en el caso de las observaciones, caracterizando la influencia de procesos a escala regional: la sequía y el rango diurno de temperatura, y la influencia de procesos a escala global, como la radiación solar en superficie. Finalmente se aplica GLAM para proyectar el rendimiento de trigo en el siglo XXI. En este caso, se utilizan los datos diarios de las variables requeridas por GLAM de diferentes modelos CMIP5 y se simulan los rendimientos como en el caso de las observaciones. Este método es diferente que el aplicado para obtener las proyecciones con los modelos empíricos.

4.3. Modelo agrícola: “The general large-area model (GLAM) for annual crops”

Tabla 4.1: Parámetros modificados con ‘GLAM Optimiser’ para el trigo de invierno y sus rangos. La primera columna indica el acrónimo del parámetro. La segunda columna contiene una breve descripción del parámetro. La tercera y cuarta columnas muestran los valores mínimos y máximos, respectivamente, de cada parámetro. Finalmente, la quinta columna muestra las referencias de cada parámetro

Acrónimo del parámetro	Descripción	Min	Max	Referencia
$\left(\frac{\partial L}{\partial t}\right)_{E_{max}}$	Max daily increase in LAI (<i>per day</i>)	0.06	0.15	Friend et al. (1962) Kemp & Blacklow (1982)
C_G	Soil heat flux constant	0.22	0.51	Choudhury et al. (1987)
S_{cr}	Critical value of soil water stress factor for leaves	0.5	1.0	Meyer & Green (1981)
EFV	Extraction front velocity (<i>cm/day</i>)	0.5	3.0	Barley (1970)
Z_{ed}	Depth of soil from which evaporation occurs (<i>cm</i>)	8.4	84.0	Challinor et al. (2004)
A	Mean albedo of the surface	0.17	0.38	Fuller & Ottke (2002)
C_{d3}	Constant for drainage	0.75	0.95	Challinor et al. (2004)
$\left(\frac{d(L_v)}{d(LAI)}\right)$	Root length density by volume	0.5	5.0	Gajri & Prihar (1985)
K_{DIF}	Uptake diffusion coefficient (<i>cm²/day</i>)	0.06	0.14	Challinor et al. (2004)
L_{cr}	LAI below which transpiration is physiologically limited	0.6	1.2	GLAM-R2 (2009)
$T_{T_{max}}$	Max potential transpiration rate (<i>cm/day</i>)	0.15	0.4	Challinor et al. (2004)
TE	Transpiration efficiency (<i>Pa</i>)	1.3	4.5	Stöckle & Nelson (2000)
$\frac{\partial HI}{\partial t}$	Rate of change of harvest index (<i>per day</i>)	0.0042	0.0098	GLAM-R2 (2009)
$E_{TN,max}$	Maximum of normalised transpiration efficiency (<i>g/kg</i>)	1.5	5.0	Cooper (1987)
T_{tt2}	Grain-filling to end of grain filling (<i>°K</i>)	328	543	Li (2008)
T_{tt3}	End of grain filling to harvest (<i>°K</i>)	80	100	Li (2008)
EN	Intrinsic earliness	0.6	1.0	Cao & Moss (1997)
V_R	Vernalisation requirement (<i>days</i>)	0	55	Cao & Moss (1997)

4.4. Comparación de modelos empíricos y basado en procesos

Para responder a la cuestión específica sobre el impacto del cambio climático en el rendimiento de trigo proponemos dos modelos empíricos y uno basado en procesos. Sin embargo, la cuestión que se nos plantea es: ¿qué modelo es más fiable?, puesto que todos los modelos individuales CMIP5 y el multimodelo presentan un rango de incertidumbre en cuanto a la tendencia que proyectan (Deser et al. 2012, González-Reviriego et al. 2015). Esta diversidad en los valores de las tendencias puede deberse a la contribución de la variabilidad interna de los modelos individuales. De modo que, para discernir la contribución de la variabilidad interna de la del forzamiento, debido a la tendencia, sería necesario desarrollar un análisis con diferentes realizaciones del mismo modelo (Deser et al. 2014), estudio que queda fuera de este trabajo debido al número de realizaciones de los modelos utilizados. Sin embargo, para cuantificar el grado de incertidumbre de cada modelo se propone un método para determinar la señal de tendencia común con respecto a la variabilidad de la tendencia que proyecta cada modelo. Es decir, ¿cuál es la contribución del forzamiento debido al calentamiento global respecto a la tendencia debida a la variabilidad interna en la tendencia del rendimiento del trigo? Para ello, se obtiene una aproximación de las contribuciones relativas de la variabilidad forzada y no forzada de los modelos mediante una relación señal/ruido (SNR; González-Reviriego et al. 2015), que se calcula de la siguiente manera para cada modelo agrícola:

1. Se promedian las componentes de tendencia de todos los modelos CMIP5 para obtener la tendencia debida al forzamiento externo:

$$T_m = \frac{\sum_{i=1}^n T_i}{n} \quad (4.67)$$

donde T_i es la tendencia de cada modelo y T_m es la tendencia común.

2. Se resta a la componente de tendencia de cada modelo (T_i) la componente de tendencia común debida al forzamiento:

$$V_i = T_i - T_m \quad (4.68)$$

4.4. Comparación de modelos empíricos y basado en procesos

La serie resultante (V_i) puede considerarse como una aproximación de la tendencia no debida a forzamientos sino a variabilidad interna, compuesta por variabilidad interna y variabilidad estructural (Deser et al. 2014).

3. De la componente de tendencia común (T_m), se calcula su pendiente o valor de tendencia ($\overline{T_m}$). Y de las componentes de tendencia individual debida a la variabilidad interna (V_i), se calcula su pendiente o tendencia ($\overline{V_i}$)
4. La relación SNR¹⁴ se define como el cociente entre el valor de la tendencia común ($\overline{T_m}$) y la desviación estándar de las tendencias individuales (σ_m).

$$SNR = \frac{\overline{T_m}}{\sigma_m} \quad (4.69)$$

Con la relación SNR se obtiene un indicador de la proporción de señal debida al forzamiento que proporciona cada modelo empírico y el basado en procesos. De manera que, si los valores resultantes de la relación SNR son superiores a 1 indican que la tendencia forzada domina frente a la variabilidad interna.

Por lo tanto, esta relación puede interpretarse como una medida de la señal común de tendencia, debida al forzamiento, y dispersión de la tendencia debida a la variabilidad interna. Asimismo, en esta tesis doctoral se ha utilizado para comparar la incertidumbre de los diferentes métodos utilizados para la proyección del rendimiento de trigo.

¹⁴Acrónimo del término inglés Signal to Noise Ratio.

CAPÍTULO 5

Resultados



5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

En este capítulo se muestran los resultados de la investigación estructurados de acuerdo a las tres publicaciones a las que ha dado lugar. La sección 5.1 incluye un resumen y conclusiones del artículo: “Effects of diurnal temperature range and drought on wheat yield in Spain”, publicado en la revista *Theoretical and Applied Climatology* por la autora de esta tesis, Hernández-Barrera S, su directora, Rodríguez-Puebla C y su supervisor durante su estancia de investigación, Challinor AJ. La sección 5.2 incluye un resumen y conclusiones del artículo: “Wheat yield in Spain and associated solar radiation patterns” publicado en la revista *International Journal of Climatology* por la autora de esta tesis, Hernández-Barrera S y su directora, Rodríguez-Puebla C. La sección 5.3 incluye un resumen y conclusiones del artículo “Assessing GLAM-wheat simulation to estimate variability and projected trend of wheat yield in Spain”, en revisión, por la autora de esta tesis, Hernández-Barrera S, su directora Rodríguez-Puebla C, Jennings S y su supervisor durante su estancia de investigación, Challinor AJ. Cada sección va acompañada de la copia de la publicación, junto con el material suplementario.

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

5.1.1. Resumen

Este estudio tiene por objeto proporcionar una nueva percepción de la respuesta del rendimiento del trigo de España a los procesos climáticos mediante el uso de métodos empíricos. En esta investigación se utilizan datos de rendimiento del trigo observado, datos climáticos pseudo-observados para el período 1979-2014, y las salidas de los modelos de circulación general del Proyecto de Intercomparación de Modelos Acoplados de la fase 5 (CMIP5) para el período 1901-2099. Para investigar la influencia del clima en la variabilidad del trigo se ha aplicado el método regresión por mínimos cuadrados parciales (PLS), que determina los modos de variabilidad climática asociados a las variaciones del rendimiento del trigo. Se encontró que los principales procesos para caracterizar la variabilidad del rendimiento del trigo en España son las sequías de otoño y primavera, y el rango diario de temperatura durante el invierno. Estos procesos climáticos observables se han usado para obtener un modelo empírico

en el período observado. El modelo se ha aplicado para proyectar las tendencias del rendimiento del trigo en España bajo diferentes condiciones climáticas. Para aislar las tendencias de las series temporales del trigo se ha implementado el enfoque adaptativo conocido como descomposición empírica en modos por conjuntos (EEMD). Los rendimientos de trigo en el siglo XXI están experimentando una tendencia decreciente como consecuencia de la sequía generalizada sobre la Península Ibérica y el aumento del rango diurno de temperatura. Estos resultados son importantes para informar sobre la vulnerabilidad del trigo en esta región a los cambios venideros y para desarrollar estrategias de adaptación.

Palabras clave: Impacto del cambio climático · Modelo empírico del rendimiento del trigo · Regresión por mínimos cuadrados parciales · Variabilidad climática

5.1.2. Puntos de partida y recursos

Las cuestiones planteadas para desarrollar esta investigación fueron:

1. ¿Qué variables climáticas o procesos derivados en escala regional son esenciales para explicar los cambios en el rendimiento del trigo?
2. ¿Qué tendencias experimentará el rendimiento del trigo considerando estos hallazgos con respecto a estas variables?

Para su desarrollo se utilizaron los siguientes datos: serie histórica del rendimiento del trigo para toda España que comprende el periodo 1979-2014; datos climáticos pseudo-observados E-OBS con una resolución de 0.25° correspondientes al mismo período que el rendimiento del trigo. Se han utilizado los datos diarios de precipitación (rr), temperatura media (T_{mean}), máxima (T_{max}) y mínima (T_{min}). De los datos de precipitación se deriva el índice de precipitación estandarizado (SPI), y de las temperaturas se deriva el rango diurno de temperatura (DTR), como se especifica en el Capítulo 3. Las variables climáticas mensuales y diarias de precipitación, temperatura media, máxima y mínima de 12 modelos CMIP5 (ver Capítulo 3) para el período 1901-2099, utilizando las simulaciones “Historical” y las “RCP8.5”.

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

Los métodos que se han aplicado para llevar a cabo este estudio son:

- ◇ Descomposición Empírica en modos por conjuntos (EEMD). Este método se ha aplicado como un filtro de pasa alta para retener todas las IMFs excepto el residual de la serie histórica del rendimiento del trigo observado, y como un filtro de pasa baja para obtener la componente de tendencia del rendimiento de trigo simulado a partir de los modelos CMIP5.
- ◇ Regresión por mínimos cuadrados parciales (PLS) para identificar los factores climáticos que explican la variabilidad del trigo (ver Capítulo 4). La regresión PLS se ha aplicado de dos maneras diferentes. Por un lado, se ha aplicado para evaluar los modos de los campos climáticos en conjunción con la variabilidad del rendimiento del trigo observado para el período 1979-2014. En este caso, las variables climáticas observadas T_{max} , T_{min} , T_{mean} , SPI y DTR ($X(T,M)$) son las variables independientes y el rendimiento de trigo observado ($Y(T)$) es la variable dependiente. Las componentes PLS ($B(T)$) correspondientes a los diferentes campos climáticos se utilizan para determinar el modelo de predicción empírica para el rendimiento del trigo. Para lo cual se aplica la regresión paso a paso (ver Capítulo 4), que selecciona las variables climáticas que se incluirán en el modelo agroclimático empírico. La incertidumbre del modelo y el intervalo de confianza en la estimación del modelo se evalúa con el método de validación cruzada (ver Capítulo 4). Además, la calidad del modelo está dada por el coeficiente de Pearson (ver Capítulo 4), y su error se obtiene con el método de remuestreo bootstrap (ver Capítulo 4). Por otro lado, la regresión PLS se aplica para encontrar las estructuras y series temporales de los patrones de las variables climáticas asociados con el rendimiento de trigo, obtenidos previamente, en conjunción con los datos CMIP5. En este caso, los datos de CMIP5 ($X'(M,T)$) son las variables independientes y los patrones espaciales de las variables climáticas ($Z(M)$) son las variables dependientes. Las series temporales ($B'(T)$) proporcionadas por la regresión PLS, correspondientes a las variables climáticas de CMIP5, se utilizan para proyectar la variabilidad del rendimiento del trigo. Este procedimiento se aplica a cada modelo individualmente antes de calcular el multimodelo como el promedio de los resultados obtenidos de todos los modelos. Además, los cambios en el rendimiento del trigo se obtienen con el estimador de Sen (ver Capítulo 4), y la significación de

la tendencia con el test estadístico de Mann-Kendall teniendo en cuenta el efecto de autocorrelación (ver Capítulo 4).

5.1.3. Discusión y conclusiones

Filtrado de la componente de tendencia del rendimiento histórico del trigo. EEMD se ha aplicado para descomponer la serie temporal del trigo en componentes o funciones de modo intrínsecas (IMFs), como se ha explicado en el Capítulo 4, con el objetivo de aislar las distintas señales de escalas temporales específicas y la componente residual, también conocida como tendencia. En la Figura 5.1a, se muestra la serie histórica del rendimiento del trigo inicial (línea roja) y la serie ya sin tendencia (línea negra). La Figura 5.1b corresponde con la componente de tendencia, y la Figura 5.1c, la Figura 5.1d y la Figura 5.1e muestran las tres IMFs en las que se descompone el rendimiento del trigo. Cada una de estas componentes representa una escala de variabilidad del rendimiento del trigo: la componente de tendencia representa el 31 % de la variabilidad total del trigo; y la primera, segunda y tercera IMFs contienen el 33, 14, y 22 % de la variabilidad total, respectivamente. Por lo tanto, en este estudio se retienen las tres IMFs que representan al rendimiento del trigo sin tendencia (Figura 5.1a), de esta manera se trata de evitar efectos externos que interfieren en estudios sobre el clima y agricultura.

Efectos de las variables climáticas en la productividad del trigo. En este estudio se evalúan las relaciones entre el rendimiento de trigo y las variables climáticas en las diferentes estaciones, que son el otoño (SON), el invierno (DJJ) y la primavera (MAM) debido a que las variables climáticas pueden afectar al rendimiento del trigo de manera diferente desde la siembra a la cosecha.

La primera estimación que se ha realizado para vincular el rendimiento del trigo a la variabilidad del clima es a través del uso de mapas de correlación entre la serie del rendimiento del trigo y los campos climáticos sobre España. Por lo que, se han encontrado relaciones positivas en otoño y primavera para el SPI, como se muestran en la Figura 5.2a y la Figura 5.2b, y para la temperatura mínima en invierno (Figura 5.2e). Por otro lado, se encontraron relaciones negativas en primavera para la temperatura máxima (Figura 5.2d) y en el invierno para el DTR (Figura 5.2c). Las áreas sombreadas de los mapas de

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

correlación indican cuando la correlación es superior a $|0.50|$. También se evalúa la sensibilidad del rendimiento del trigo a SPI, DTR, T_{max} y T_{min} . Se observa, que el SPI en SON y en MAM producen un aumento en el rendimiento del trigo, presentando mayor sensibilidad en MAM. No obstante, el DTR en DJF provoca una disminución en el rendimiento del trigo. Por lo tanto, los hallazgos empíricos muestran el daño que implican las heladas en invierno y el calor en primavera.

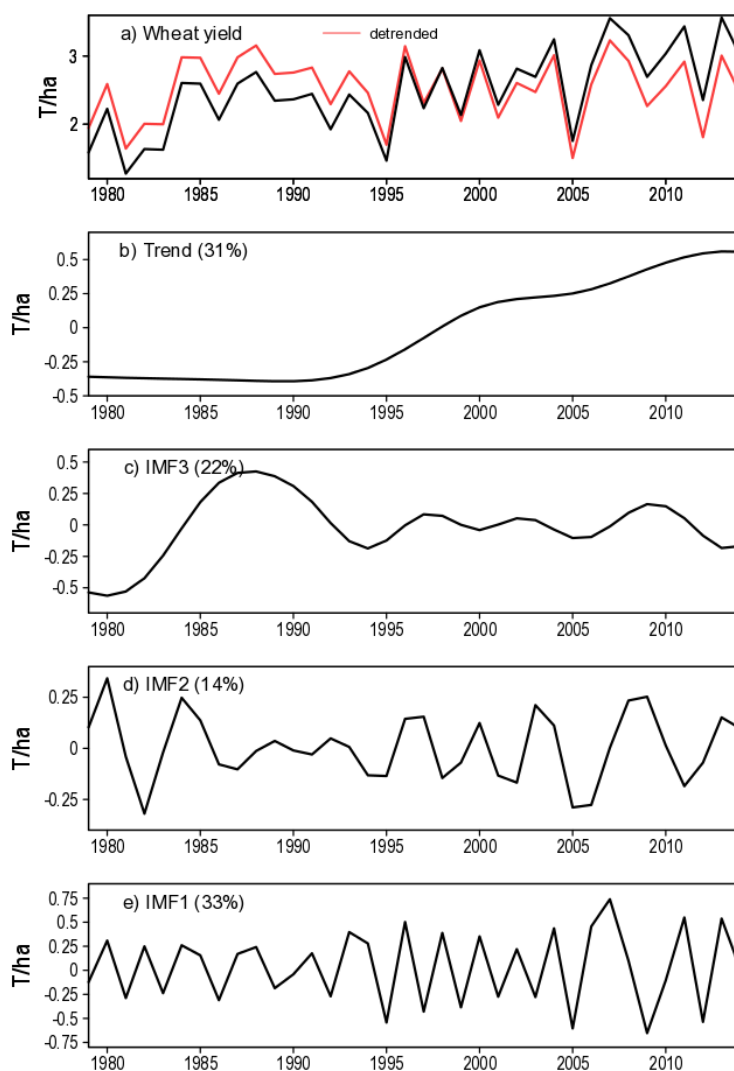


Figura 5.1: Serie temporal del rendimiento del trigo observado (roja) y sin tendencia (negro) (a), de las componentes de tendencia (b) y las funciones de modo intrínseco (IMFs) (c-e), teniendo en cuenta el porcentaje de varianza contabilizada

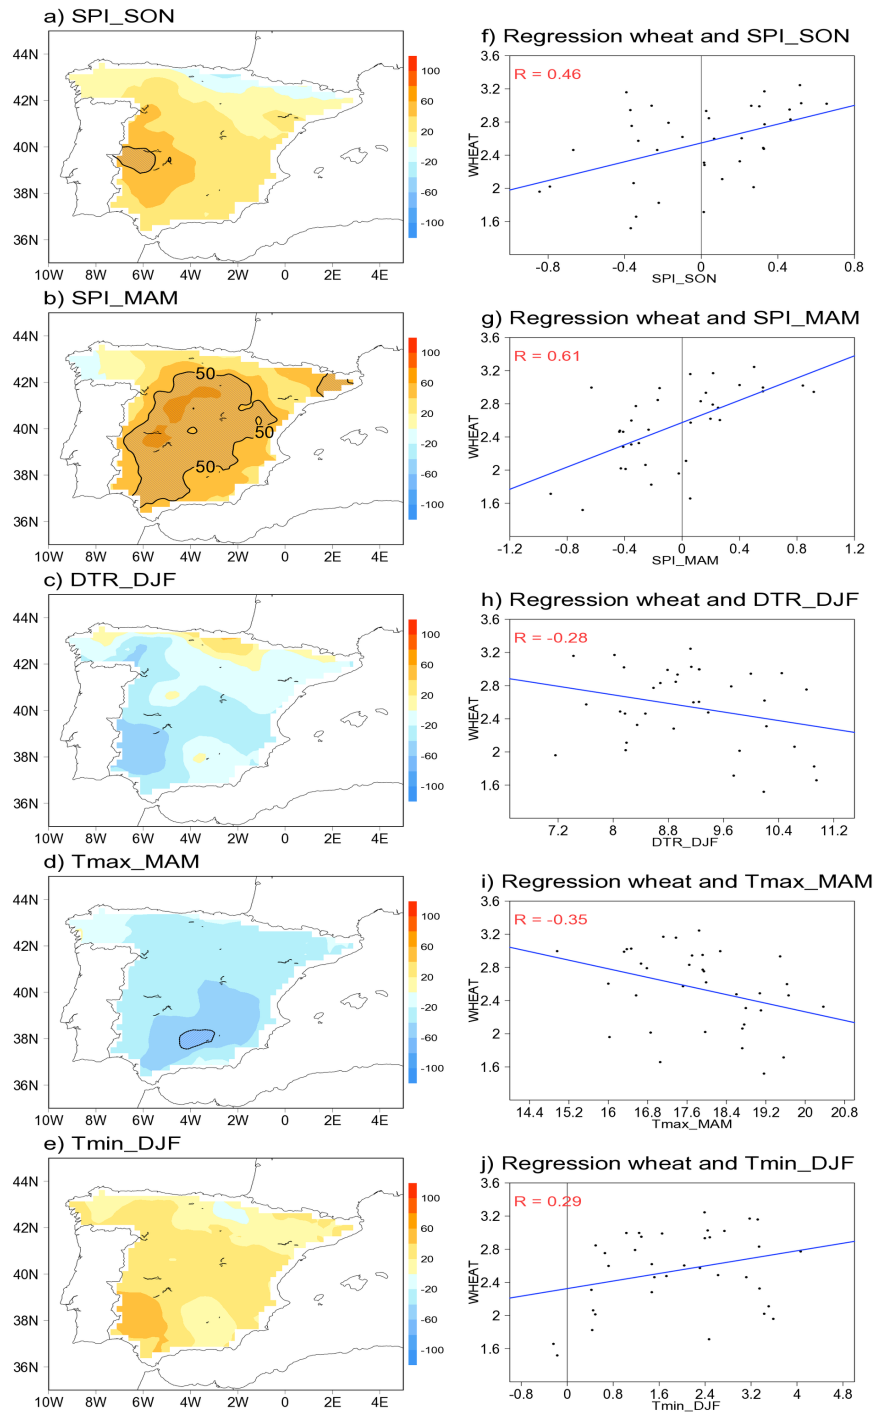


Figura 5.2: Correlación entre el rendimiento de trigo sin tendencia y las variables climáticas donde las áreas sombreadas indican una correlación superior del $|0.50\%$ para; SPI en otoño (a) y en primavera (b); DTR en invierno (c); T_{max} en primavera (d); T_{min} en invierno (e). Los gráficos de dispersión representan el rendimiento de trigo frente a: SPI promediado en otoño (f) y en primavera (g); DTR promediado en invierno (h); T_{max} en primavera (i); T_{min} en invierno (j). R corresponde con la correlación de la ecuación de regresión

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

Estos resultados están de acuerdo con el estudio de Rodríguez-Puebla et al. (2007) y con Gouache et al. (2015), que informó sobre la importancia de la sequía y el estrés térmico en los rendimientos durante el llenado del grano. Wu et al. (2014) también indicaron la importancia de las lluvias en primavera, además, de que la escarcha y el calor son factores que reducen el rendimiento del cultivo.

Selección de variables y modelo estadístico. La regresión PLS determina los modos espacio-temporales de las variables climáticas que explican la covarianza máxima entre el rendimiento de trigo y los datos climáticos, como se ha explicado con anterioridad, proporcionando un ajuste dinámico del rendimiento del trigo utilizando diferentes variables climáticas. La Figura 5.3 muestra las estructuras o patrones espaciales de las variables seleccionadas por el modelo estadístico que incluye el SPI de SON y MAM y el DTR de DJF, donde las áreas sombreadas indican que la correlación es superior a $|0,50|$ y que la significación de la prueba estadística p es menor de 0.01. La Figura 5.3a y la Figura 5.3b sugieren que el rendimiento mayor se obtiene cuando menos eventos de sequías ocurren en SON y MAM, y la Figura 5.3c indica que a valores más bajos de DTR, aumenta la productividad del trigo en DJF. Además, los patrones de SPI en SON y MAM y DTR en DJF representan el 39, 65 y 51 % de la variabilidad del SPI y DTR, respectivamente. Se demuestra que la regresión PLS es útil para caracterizar los efectos climáticos sobre el rendimiento del trigo, debido a que las componentes PLS de las diferentes variables climáticas representan mejor el ajuste que las series de las variables climáticas espacialmente promediadas en España.

Los predictores potenciales que inicialmente tienen influencia en el rendimiento del trigo eran el SPI en SON y MAM, DTR en DJF y MAM, T_{min} en DJF y T_{max} en MAM. Por lo que, estas variables se utilizaron para determinar qué factores climáticos influyen en el rendimiento del trigo, utilizando el método de regresión con selección de variables mediante el método “paso a paso”, que ha sido explicado en el capítulo anterior. Por lo tanto, las variables seleccionadas por la regresión paso a paso son el SPI en SON y MAM, y el DTR en DJF. El efecto de la T_{max} en MAM queda representado en el SPI, y el efecto de T_{min} queda representado en el DTR en DJF. En la Figura 5.4 se muestra el resultado del modelo, que explica casi el 63 % de la variabilidad del rendimiento del trigo. Y además, las áreas sombreadas representan el intervalo de confianza de los resultados, que se obtienen utilizando el método bootstrap

con 500 realizaciones. El modelo estadístico se define:

$$Y = 0,96 \cdot B(SPI_SON) + 0,94 \cdot B(DTR_DJF) + 1,44 \cdot B(SPI_MAM) \quad (5.1)$$

donde Y corresponde con el rendimiento de trigo, $B(SPI_SON)$ y $B(SPI_MAM)$ son las componentes PLS representativas de las variables SPI en otoño y primavera, respectivamente, y $B(DTR_DJF)$ es la componente PLS representativa de DTR en invierno.

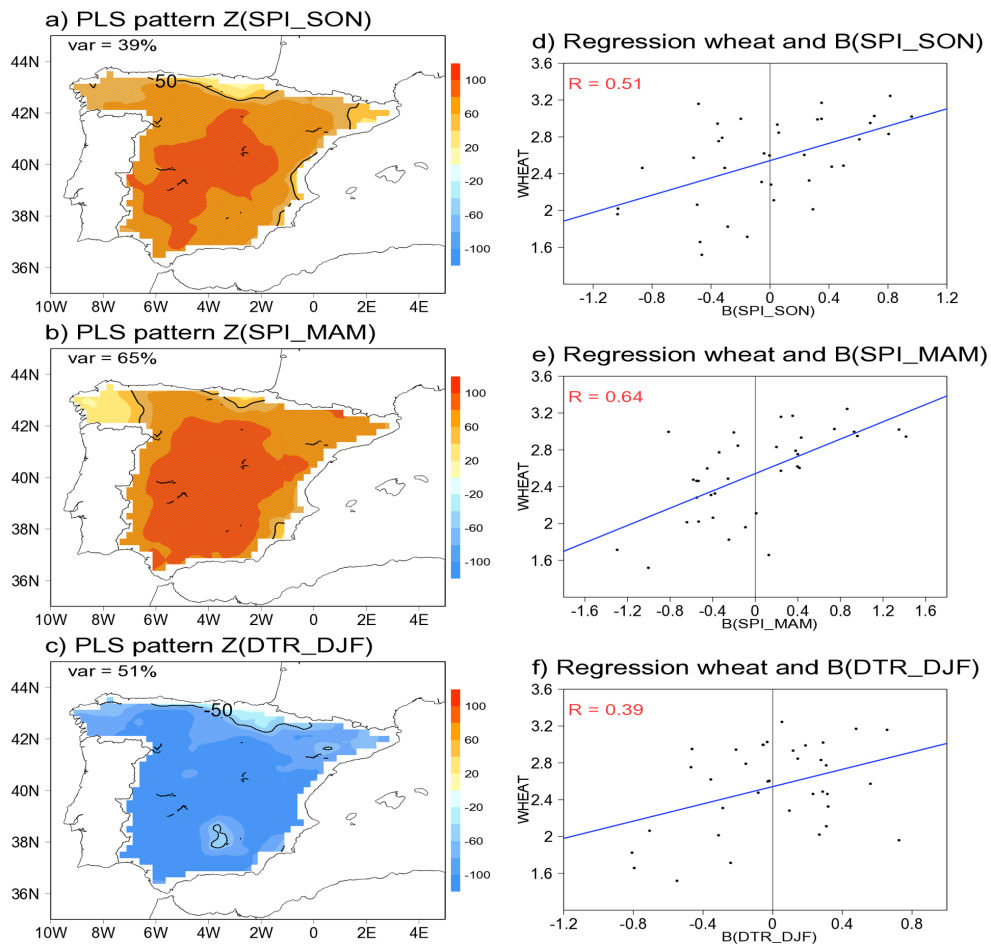


Figura 5.3: Patrones de la regresión PLS derivados de las series temporales de trigo y los campos climáticos, las áreas sombreadas indican una correlación superior del $|0.50\%|$ para; SPI en otoño (a), SPI en primavera (b) y DTR en invierno (c). Los gráficos de dispersión representan el rendimiento de trigo frente a los índices representativos de: SPI en otoño (d), SPI en primavera (e) y DTR en invierno (f)

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

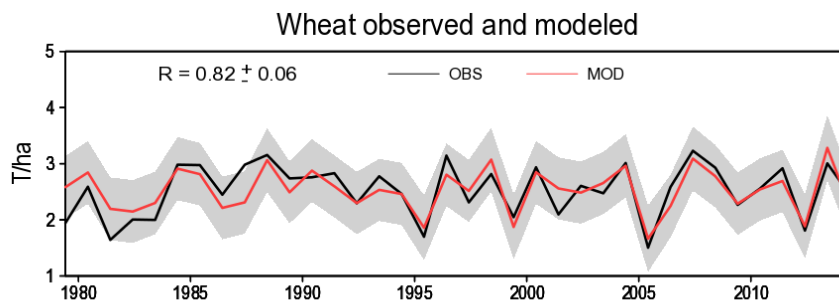


Figura 5.4: Serie temporal del rendimiento del trigo observado (negro) y del rendimiento del trigo simulado por el modelo agroclimático (rojo). El sombreado gris indica el intervalo de confianza del modelo. El coeficiente de correlación entre ambas series es $0,82 \pm 0,06$

Por lo tanto, se ha encontrado que las sequías producen diferentes efectos en las distintas fases del crecimiento del trigo, siendo mayores durante la fase de madurez. Estos hallazgos son justificados con el estudio de Oteros et al. (2015) que investigaron la influencia de la precipitación sobre los cambios en la fenología del trigo en España, señalando que los cambios más marcados se producen en primavera. Además, diferentes autores han encontrado que la precipitación tiene un efecto positivo en los rendimientos globales de trigo (Challinor et al. 2014, Luo & Wen 2015). Sin embargo, otros estudios han encontrado que demasiada lluvia puede afectar negativamente al trigo (Rotter et al. 2013).

Por el contrario, un aumento de DTR en invierno provoca una reducción de la productividad del trigo en España, este hallazgo se puede justificar con la influencia positiva del aumento de T_{min} en invierno, que se obtuvo previamente. Del mismo modo, Chen et al. (2015) en China y Lobell (2007) en Australia y Canadá obtuvieron relaciones opuestas entre el DTR y el trigo. Asimismo, Nicholls (1997) muestra que el rendimiento del trigo presenta una respuesta negativa al aumento del DTR.

Retrospectivo y futuro rendimiento del trigo utilizando modelos CMIP5. Para determinar las proyecciones de las condiciones climáticas y del rendimiento de trigo en España, se analizaron los rendimientos obtenidos a través del uso de las salidas de los modelos CMIP5, en particular las variables especificadas en el modelo agroclimático, teniendo en cuenta su importancia relativa (5.1). Para ello, se ha implementado la regresión PLS en el modo espacial, como se explica en el Capítulo 4. Por lo que, la regresión PLS se aplica

a las variables SPI en SON y MAM y DTR en DJF en cada modelo individual. Entonces, las series temporales derivadas o componentes PLS se multiplican por los coeficientes del modelo agroclimático empírico para determinar la simulación del rendimiento del trigo. A partir de las simulaciones del rendimiento del trigo de cada modelo, se calcula la simulación promedio o del multimodelo. El estudio se centra en analizar el cambio de tendencia del rendimiento de trigo de los modelos individuales y del multimodelo. Para ello, se utiliza el método no paramétrico EEMD para aislar la componente de tendencia (Figura 5.5).

La mayoría de los modelos presentan una tendencia de reducción del rendimiento del trigo, siendo más pronunciada para el multimodelo a lo largo del período 1901-2099. Sin embargo, esta tendencia no es estacionaria ya que presenta un aumento en algunos períodos. De modo que, se comparan las tendencias a lo largo de los siglos XX y XXI (Figura 5.6), cuantificando las variaciones (T/ha en 100 años) a través del estimador de Sen y midiendo su significación con la prueba de Mann-Kendall, como se explica en el Capítulo 4. En el caso del multimodelo, estos resultados indican una disminución del rendimiento del trigo de 0.4T/ha para el período que abarca desde 1901 a 2000, y en el período 2001-2099 se observa una disminución de 0.8T/ha, lo que representa una reducción del 16 y 32 %, respectivamente.




Figura 5.5: Series temporales de las tendencias filtradas del rendimiento de trigo simulado a partir de los modelos CMIP5 (línea de colores) y el multimodelo (línea negra)

Para corroborar estos resultados, se proporciona una estimación de la distribución de datos del rendimiento de trigo a través de un diagrama de cajas (ver Capítulo 4). En la Figura 5.7, se compara el rendimiento del trigo observado con los rendimientos de los modelos individuales y el multimodelo entre el período observacional (1979-2014) y su correspondiente período en el futuro

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

(2070-2099). El multimodelo predice una disminución en la mediana con una variabilidad similar en el futuro, en comparación con el período observacional.




Figura 5.6: Valores obtenidos del test del estimador de Sen (Sen) y del test de Mann-Kendall (Z) para evaluar los cambios en el rendimiento del trigo en los siglos XX y XXI obtenidos mediante los modelos CMIP5. Los valores de Sen y Z que indican tendencia significativa positiva (negativa) están sombreados en rojo (azul)

Los cambios proyectados en el rendimiento del trigo probablemente se deben a la evolución de las variables incorporadas en el modelo agroclimático, es decir, se debe a los cambios del SPI en SON, MAM y del DTR en DJF. Además, los modelos informan de una tendencia hacia un clima más seco en el futuro (IPCC 2013), como se ha mencionado a lo largo de esta tesis doctoral. Por otro lado, Franzke (2015) encontró que DTR aumentará en España, lo que puede causar una reducción en el rendimiento del trigo. Por lo tanto, en la Figura 5.8 se muestra la evolución de las variables SPI y DTR obtenidas para el multimodelo, observándose una tendencia decreciente para SPI en SON y MAM, y una tendencia creciente para DTR en DJF, lo que apoya que la reducción del rendimiento del trigo es debida a la influencia del SPI y DTR durante el desarrollo del trigo.




Figura 5.7: Diagrama de Cajas que compara los rendimientos de trigo obtenidos a partir de las salidas de los modelos CMIP5. En cada diagrama están representadas la distribución de probabilidad del rendimiento para los períodos 1979-2014 (azul) y 2070-2099 (rojo). En cada caja, el punto indica la mediana de la distribución, los bordes superiores o inferiores de la caja indican los percentiles 75 y 25, respectivamente, y las barras superiores e inferiores corresponden a los valores extremos. Los valores negativos se cambiaron por 0

Por lo tanto, estos resultados revelan que el rendimiento del trigo disminuirá en el siglo XXI en España si no se tiene en cuenta el efecto del CO_2 . Lo que está de acuerdo con otros estudios que proyectan el rendimiento del trigo utilizando diferentes enfoques, como es el caso de Moore & Lobell (2014) y Pirttioja et al. (2011) que mostraron que el rendimiento del trigo disminuirá en Europa. Estas disminuciones pueden deberse a la vulnerabilidad de los cultivos a fenómenos climáticos extremos (Coumou & Rahmstorf 2012, Trenberth 2012, WMO 2013, entre otros). Por otro lado, se puede esperar que los efectos de fertilización aumenten con el aumento del CO_2 . Sin embargo, existen ciertas incertidumbres en la simulación de los impactos en el rendimiento de trigo con el CO_2 , ya que unos estudios informan de un aumento en el rendimiento del trigo (Supit et al. 2012) y otros, presentan un impacto negativo en el rendimiento del trigo (Asseng et al. 2013, Deryng et al. 2014).

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

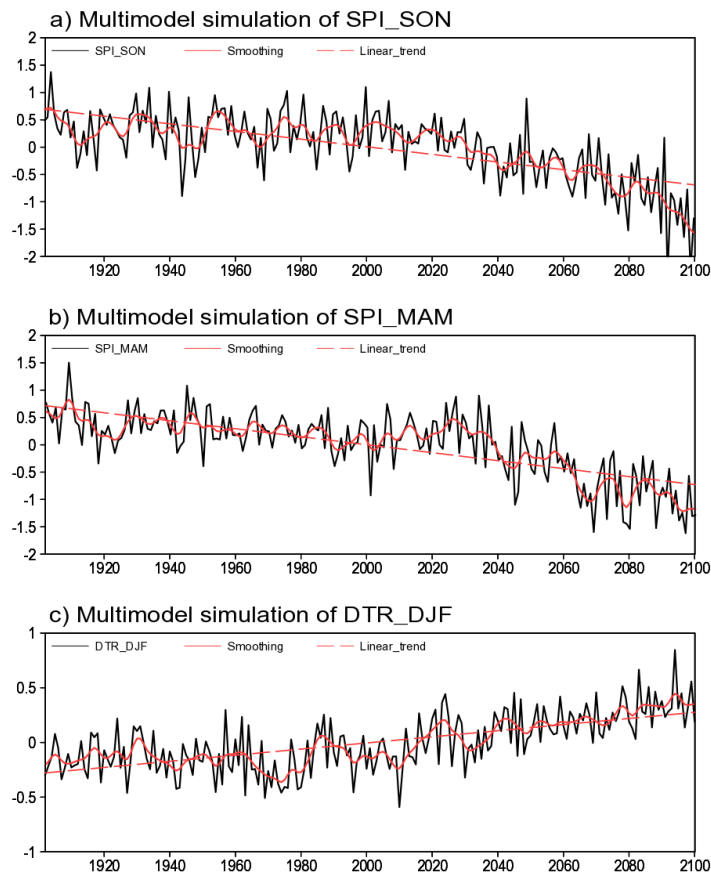


Figura 5.8: Series temporales espacialmente promediadas en España del SPI en otoño (a), SPI en primavera (b) y del DTR en invierno (c) correspondientes a la simulación del multimodelo. La línea negra representa la simulación, la línea roja corresponde con un suavizado de 15 años y la línea discontinua roja indica la tendencia lineal

5.1.4. Article “Effects of diurnal temperature range and drought on wheat yield in Spain” and Supplementary Material



Effects of diurnal temperature range and drought on wheat yield in Spain

S. Hernandez-Barrera¹ · C. Rodriguez-Puebla¹ · A. J. Challinor²

Received: 26 November 2015 / Accepted: 16 March 2016
© Springer-Verlag Wien 2016

Abstract This study aims to provide new insight on the wheat yield historical response to climate processes throughout Spain by using statistical methods. Our data includes observed wheat yield, pseudo-observations E-OBS for the period 1979 to 2014, and outputs of general circulation models in phase 5 of the Coupled Models Inter-comparison Project (CMIP5) for the period 1901 to 2099. In investigating the relationship between climate and wheat variability, we have applied the approach known as the partial least-square regression, which captures the relevant climate drivers accounting for variations in wheat yield. We found that drought occurring in autumn and spring and the diurnal range of temperature experienced during the winter are major processes to characterize the wheat yield variability in Spain. These observable climate processes are used for an empirical model that is utilized in assessing the wheat yield trends in Spain under different climate conditions. To isolate the trend within the wheat time series, we implemented the adaptive approach known as

Ensemble Empirical Mode Decomposition. Wheat yields in the twenty-first century are experiencing a downward trend that we claim is a consequence of widespread drought over the Iberian Peninsula and an increase in the diurnal range of temperature. These results are important to inform about the wheat vulnerability in this region to coming changes and to develop adaptation strategies.

Keywords Climate change impact · Empirical wheat yield model · Partial least square regression · Climate variability

1 Introduction

The IPCC (2014) report on impacts, adaptation, and vulnerability informs that rising temperatures and changes in rainfall may benefit agriculture in some countries but may damage in some other parts, as consequence of climate variability, weather extremes, and changes of the water cycle. The Joint Research Centre (JRC) denoted a reduction around 20 % of agricultural production in Southern Europe by the end of the twenty-first century, in the PESETA II Project on impact studies in Europe (Ciscar et al. 2014). They also refer that the technical adaptation can improve the yields all over Europe; however, modest effectiveness is expected in southern Spain due to excessive aridity. Particularly in Spain, there is currently a national concern about agricultural productions. Wheat is one of the worlds most basic and necessary, its productivity is as large as olive, citrus, and grape farming in Spain (FAO 2014). Our study aims to address the following questions: what climate variables are essential to explaining wheat yield changes? What future trends will wheat production experience considering our findings regarding these variables?

Electronic supplementary material The online version of this article (doi:10.1007/s00704-016-1779-9) contains supplementary material, which is available to authorized users.

✉ C. Rodriguez-Puebla
concha@usal.es

¹ Department of Fundamental Physics, University of Salamanca, Plaza de la Merced s/n, 37008 Salamanca, Spain

² School of Earth and Environment, University of Leeds, Leeds LS2 9JT, UK

Some of the motivations to perform this study are diversity of results on climate change and crop impacts; variety in crop methodologies; and the need to evaluate the impacts of climate change on crops variability at the regional level. The methods to evaluate the impact of climate change on crop productions can be gathered into process-based and statistical models. White et al. (2011) reviewed methodologies for simulating impacts of climate change on crop productions using process-based crop models, which succeed locally. However, Palosuo et al. (2011) noticed that process-based crop models for winter wheat simulation reproduce poorly the corresponding observations, since agricultural management input data are seldom available for larger areas. Otherwise, Angulo et al. (2013) discussed the regionally applicability of process-based crop models. Rosenzweig et al. (2013) indicated that wheat simulation is more sensitive to the crop model than to global climate model simulation and Carter (2013) recommended multi-model yield projections for impact studies. Some authors (Rotter and Hohn 2015; Asseng et al. 2013) performed inter-comparisons of process-based crop models by analyzing the uncertainty of wheat simulation under climate change and considering differences in model structures. A meta-analysis from numerous studies indicated that projected response of crop to climate variability and change can vary according to the methodology (Challinor et al. 2014). However, process-based models are useful for determining the causes of yield variations while to reproduce historical yield variations statistical models are appropriated (Watson et al. 2015). Thus, statistical approaches are attracting attention for assessing climate change impacts on crop production for larger areas (Lobell and Burke 2010; Lobell 2013).

Regarding wheat yield, Lobell et al. (2011a) studied the impact of climate trend on global crop production and Moore and Lobell (2014) point out the benefits of adaptation to compensate the negative effect of rising temperature on the crops in Europe. The impacts of climate change on winter wheat are thought to be negative across Europe (Olesen et al. 2011). Trnka et al. (2011b) calculated and projected agroclimate indices, reported decreases in potential productivity in the case of North and South Mediterranean zones due to increases in the proportion of dry days, and increase in heat waves.

The majority of agro-climatic investigations focussed on analysing the relationships between crop yield, temperature, and precipitation; Challinor et al. (2014) summarized the responses of various crops to changes in temperature, precipitation, and effectiveness of adaptation. Currently, extreme indices of the apparent impacts upon ecosystems (Lobell 2007; Lobell et al. 2011b; Ruiz-Ramos et al. 2011; Trnka et al. 2014; Eitzinger et al. 2013) have garnered

much attention. Other studies develop analyses regarding the relationship between crop productions and teleconnections (Atkinson et al. 2005; Chen et al. 2015; Gonsamo and Chen 2015; Hansen et al. 2001; Iizumi et al. 2014; Podesta et al. 2002; Royce et al. 2011; Bannayan et al. 2011; Dalla Marta et al. 2011; Jarlan et al. 2014; Tian et al. 2015).

In Spain, the effects of climate variations on wheat and barley yields in the Ebro valley have been estimated by Vicente-Serrano et al. (2006) using drought indices and remote sensing data. Iglesias and Quiroga (2007) researched the risks entailed by climate variability for cereal production at five sites in Spain; Ruiz-Ramos et al. (2011) projected the effects of maximum temperature on cereal yields by using regional climate models. Studies based on teleconnections and crop productions in Spain were conducted by Capa-Morocho et al. (2014), Gimeno et al. (2002), and Rodriguez-Puebla et al. (2007). However, the responses of regional crops to climate changes are very much uncertain, as indicated by Rotter (2014), hence, multiple impact models should be considered for projecting future crop productivity (Challinor et al. 2014).

Most of the statistical studies are based on regression of the historical crop yield, precipitation, and temperatures. We aim to identify relationships between wheat variability in Spain and climate processes such as drought and extreme temperature indices, updating previous work (Rodriguez-Puebla et al. 2007) and introducing new approaches: namely, the partial least-squares (PLS) regression for ascertaining the modes of climate variables associated with wheat yield variability, Ensemble Empirical Mode Decomposition (EEMD) for identifying the trends and scales of wheat yield variability, and the multivariate regression model for empirically estimating wheat yield variability, considering the relative effects of different climate variables that affect soil moisture content as temperature and precipitation. Hence, we have not considered changes in soil water storage capacity and CO_2 variations. The empirical statistical model of wheat yield variability in Spain is applied to estimate the wheat productivity in the twentieth and twenty-first centuries, using the output data of 12 GCMs of CMIP5. We analysed the changes in wheat yields for individual models and the corresponding multi-model for historical and representative concentration pathway 8.5 (RCP8.5) experiments (Taylor et al. 2012).

The paper is organized in the following way: the data and methods used are indicated in Section 2. Results regarding the analysis of climate impact upon wheat yield, the derived statistical model, and the identification of trends under different climate conditions are presented in Section 3. Discussion and main findings are summarized in Sections 4 and 5, respectively.

2 Data and methods

2.1 Data and study area

Data regarding wheat production or yield over Spain is collected by the Spanish Agriculture, Food, and Environment Department (MAGRAMA 2015). Wheat yield refers to the weight of production divided by the area of cultivation (T/ha). We used data from different provinces for the period 1979 to 2014. Regarding the climate data in Spain (35–45N and 10W–5E), we used the daily pseudo-observations E-OBS (V11.0) dataset 0.25-degree resolution of precipitation (Pr), mean (Tmed), maximum (Tmax), and minimum (Tmin) temperatures (Haylock et al. 2008) for the period of September 1978 to August 2014. Although there are other datasets based on denser observational networks, Spain02 (Herrera et al. 2012), station density is not as relevant for purposes of this research as we are primarily interested in climate variations that affect the aggregated wheat yield in Spain. Furthermore, the Spain02 dataset was not available until 2014, while the E-OBS data are frequently updated and extensively used and tested. From the daily temperatures, we derived the daily diurnal temperature range (DTR), then the monthly and seasonal DTR. From the daily precipitation, we derived the accumulated monthly and seasonal precipitation, then we derived the Standardized Precipitation Index (SPI) (WMO 2012; Vicente-Serrano et al. 2010) on a time scale of 1 month to reflect the response of wheat yield to rapid-onset drought events (Otkin et al. 2015) or agricultural drought (Lorenzo-Lacruz et al. 2013). The SPI consists of the transformation of precipitation into a standardized normal distribution, obtained with the script of Near Command Language (NCL) (UCAR/NCAR 2015).

Our model indirectly takes into account the effect of soil moisture effect on crops, by considering both variables: precipitation, characterized with the SPI index, and temperature using the DTR index. A comparison of drought indices effect (Begueria et al. 2014) on wheat yield would be a challenge for further research since the choice of the formula to compute evapotranspiration is currently under debate (Dai 2011; Trenberth et al. 2014).

We used a second dataset of climate variables of Pr, Tmed, Tmax, and Tmin corresponding to the CMIP5 models (Taylor et al. 2012) indicated in the supplementary material (Table S1). In this study, we considered the historical experiment corresponding to the period of time from September 1901 to December 2005, forced by observed atmospheric composition changes, reflecting both anthropogenic and natural sources, and the future projection of the RCP8.5 experiment from January 2006 to August 2099, which corresponds to the pathway with the highest

greenhouse gas emissions and a radiative forcing of 8.5 W/m² in 2100 (Riahi et al. 2011). One realization or ensemble run of the individual models is taken into account in order to give all models the same weight. The DTR and SPI modeled are derived as explained above in the case of pseudo-observations. For this comparison, we have re-gridded the data to the same resolution as E-OBS using the bilinear interpolation included in the Climate Data Operator (CDO) software (Schulzweida 2015). The model performance of the GCMs selected has been evaluated through comparisons of some pattern statistics (Taylor 2001) and climographs against the observations, included in the supplementary material.

2.2 Empirical mode decomposition

Much of the yield increase is likely due to improved crop management, according to results of (Moore and Lobell 2015), since the contribution of the long-term temperature and precipitation trends to wheat yield trend is quite small during the observational period (Xiao and Tao 2014). In addition, recent study (Asseng et al. 2013) indicates the controversial benefits from enhanced CO₂. Therefore, de-trending the wheat time series is recommended before exploring the relationships between climate variability and wheat yield. EEMD is an adaptive approach to deconstructing a time series without linear or stationary assumptions (Chen et al. 2013; Huang et al. 1998; Moghtaderi et al. 2013; Wu et al. 2007). This approach acts as a high-pass filter and is used in decomposing wheat yield time series. EMD is a sifting process to decompose a time series $x(t)$:

$$x(t) = \sum_{i=1}^k c_i(t) + r(t) \quad (1)$$

Here, $c_i(t)$ are intrinsic mode functions (IMFs) and $r(t)$ is the residual. IMFs depend on the signal and satisfy two conditions (Huang et al. 1998): the number of extreme and the number of zero crossing vary by at most one, and the local mean of each IMF is zero. The decomposition procedure is as follows: (1) locate all maxima and minima of the $x(t)$ and connect all maxima (minima) with a cubic spline; (2) compute the difference between the time series and the mean of upper and lower envelopes to yield a new time series $h(t)$; (3) for the time series $h(t)$, repeat steps (1) and (2) until upper and lower envelopes are symmetric with respect to the zero mean under the specified criteria in order to obtain the IMF, $c_i(t)$; (4) subtract $c_i(t)$ from original time series $x(t)$ to yield a residual $r(t)$ and treat $r(t)$ as the original time series and repeat steps 1–3 until the residual becomes a monotonic function or a function with only

one extreme; this completes the sifting process (Chen et al. 2013). For better signal separation, a Monte Carlo approach recommended, in which zero-mean Gaussian white noise is added to each EMD process and the modified method is designed as EEMD (Franzke 2010; Wu et al. 2011).

The utility of the EEMD approach in separating the trend from natural variability in analyzing phenological responses to warming is demonstrated in the paper by Guan (2014). The robustness of EEMD has been applied in ascertaining surface air temperature trends (Capparelli et al. 2013; Ji et al. 2014) and trends in sea surface temperature (Feng et al. 2014). In our case, we use EEMD as a high-pass filter by retaining all the IMFs except the residual or trend component of the observed wheat time series; therefore, other improved techniques (Colominas et al. 2014) for analysing the intrinsic mode functions were not implemented. This method is also used to represent the trend component of the wheat yield simulation from CMIP5 models. The estimation utilized the Matlab EMD/EEMD package of Flandrin et al. (2004).

2.3 Partial least squares regression

The influence of climate variables on wheat production is investigated through the use of the PLS regression. This procedure is a powerful method for describing the covariance between variables by means of latent variables. This process entails dimension reduction and regression adjustment. The method was developed by Wold et al. (2001) in order to solve the problem of co-linearity in linear regression. It has been applied with great success in chemometrics and is now being applied in climatology (Gonzalez-Reviriego et al. 2015; Smoliak et al. 2015; Smoliak et al. 2010; Wallace et al. 2012). PLS regression seeks to predict variables (Y) based on independent variables (X) that are correlated by finding a few new uncorrelated variables, in addition to denominated latent variables. Imposing the constraint of orthogonality upon the latent variables serves to mitigate the problem of multi-linearity and reduces the number of independent variables needed to describe variations in the dependent data (Y), but PLS also chooses the optimum subset of predictors, which is not guaranteed when the Principal Regression Method is applied (Abdi 2010). Therefore, PLS finds components from X that best predict Y .

In our study, PLS regression is applied in two different ways. The first step begins to assess the modes of a climate field in conjunction with the observed wheat yield variability corresponding to the observational period (1979–2014). The modes include spatial patterns and PLS components or time series congruent with the wheat time series. We obtained tailored time series of climate variation components that explain changes in wheat yield. In this case, the observed climate variables will be referred

to as independent variables, or fields that vary in time and space dimensions $X(T, M)$, ($M = lat \times lon$), and the detrended spatially averaged wheat yield in Spain is the dependent variable, which varies within the time dimension $Y(T)$. The outcomes include some orthogonal latent spatial vectors $Z(M)$ and temporal uncorrelated PLS components $B(T)$. Figure 1a shows a schematic diagram of the PLS approach. The procedure is applied to different climate fields such as Tmax, Tmin, Tmean, SPI, and DTR. The PLS component B , corresponding to different climate fields, will be considered in predicting the dependent variable Y by applying a forward and backward stepwise regression procedure (Wilks 2006) that selects the climate indicators B to be included in the empirical agro-climate model. The uncertainty of the model was assessed through the use of cross-validation or by repeating the appropriate procedure upon data subsets to select robust variables and provide the confidence interval for the estimation. The quality of the model is given by the Pearson correlation coefficient with its error, which is obtained by repeating the correlation for many samples using a bootstrap re-sampling with replacement. To construct the empirical model, we used the package stepwise linear regression model under Matlab statistical toolbox.

The second step of PLS application considers the spatial patterns of the climate variables associated with wheat yield variations, previously obtained through applying PLS to the observational period, and these patterns were analysed in conjunction with the CMIP5 data to find their common structure and associated time series (Gonzalez-Reviriego et al. 2015). In this case, the GCMs data are the independent variables $X'(M, T)$ and the spatial patterns of the observed climate data are the dependent variables $Z(M)$. Consequently, PLS regression provides the time series $B'(T)$ of the climate GCMs variables that will be used to project wheat yield variability. The procedure is applied to each individual model before being combined the B-values to derive the corresponding B-values for the Multimodel.




Fig. 1 Schematic diagram of the PLS regression in the temporal dimension (a) and the spatial dimension (b)

Figure 1b shows a schematic diagram of this approach. The PLS computation is performed with the SIMPLS algorithm included in the Matlab statistical toolbox.

In addition, wheat yield changes were computed by means of the non-parametric Theil-Sen estimator (Sen 1968), given the trend significance with the Mann-Kendall Z test by taking the effect of serial correlation (Yue and Wang 2004) into account.

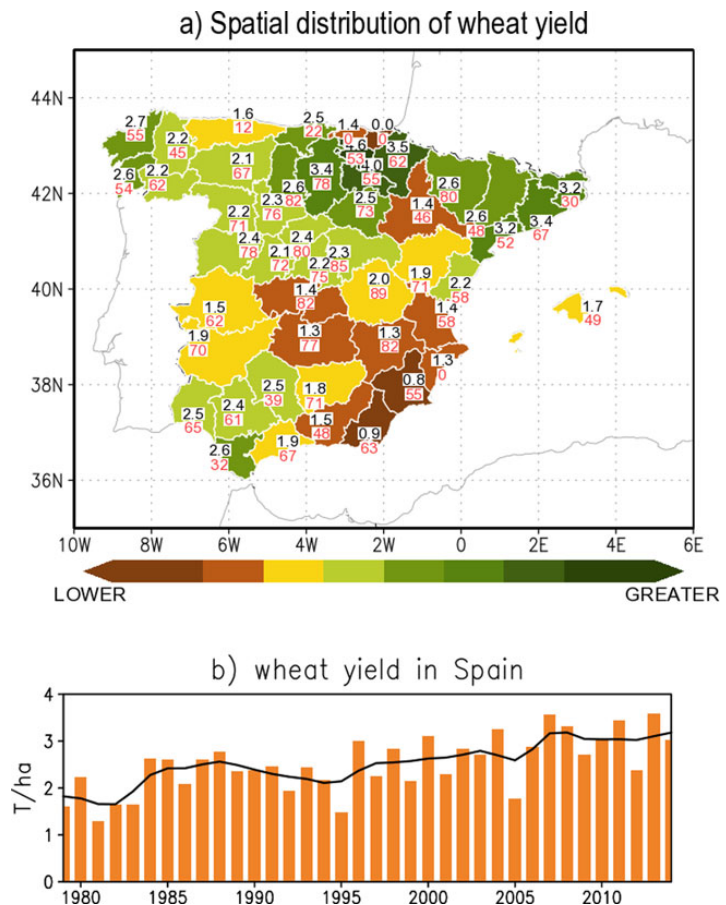
3 Results

3.1 Analysis of historic wheat yields and filtering out the trend component

Figure 2a shows the mean wheat yield across different provinces in Spain indicated with the numbers in black (T/ha). The highest values corresponding to the northeast plateau. Wheat production time series for the period 1979

to 2014 spatially averaged over the entire country is shown in Fig. 2b by a bar graph; the line represents the time series with a 6-term smoothing to illustrate the trend's progression. The representative nature of the spatially averaged wheat time series with respect to the time series in different provinces is evaluated by the Pearson correlation coefficient. These values, multiplied by 100, are indicated by the red numbers in Fig. 2a. The spatially averaged yield correlated quite significantly with the time series at every province. Therefore, the averaged time series can be used to represent the year-to-year wheat yield variability in Spain in this impact study. Table 1 depicts some statistical metrics of the wheat time series: mean, standard deviation, skewness, kurtosis, trend change (computed using the Sen's estimator), and trend significance, obtained with the Mann-Kendall Z test. These statistical parameters indicated that the wheat time series behaves as a normal distribution and shows a trend of significant increases, probably due to agronomic managements as demonstrated by Xiao and Tao (2014).

Fig. 2 **a** Spatial distribution of wheat yield over Spain (in black) (T/ha) and correlation (in red) ($\times 100$) between spatially averaged wheat yield over Spain and time series of individual provinces. **b** Time series of spatially averaged wheat yield in Spain (bars) and running mean smoothing (line)



5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

S. Hernandez-Barrera, et al.


Table 1 Statistic metrics of wheat yield time series: mean (T/ha), standard deviation (STD in T/ha), skewness (SK), kurtosis (KT), trend changes (T/ha) in 10 years (Sen’s test) and trend significance Mann-Kendal Z test (MK-Z)

Mean	STD	SK	KT	Sen	MK-Z
2.5 ± 0.19	0.60 ± 0.11	-0.13 ± 0.47	-0.65 ± 0.71	0.36 ± 0.037	3.99

We applied EEMD with the aim of decomposing the wheat time series into components or intrinsic mode functions (IMF) for the isolation of signals of specific timescales and a residual component or trend. Figure 3c, d, and e shows the three intrinsic mode functions or scales of wheat yield variability, Fig. 3a shows the initial data (black line) and the detrended time series (red line). The residual (Fig. 3b) is the trend component accounting for 31 % of the total wheat

yield variability; the first, second, and third IMFs account for 33, 14, and 22 % of total variability, respectively. In our study, we retain the three IMFs or de-trended wheat yields represented in Fig. 3a, which will be analyzed in conjunction with climate variables. The variation of the trend component may depend on several factors, as technology improvements being among the most relevant. Atmospheric $C O_2$ increase can benefit wheat yield due to the fertilization

Fig. 3 a Time series of: wheat yield (black) and detrended component (red); b trend component; (c to e) Intrinsic Mode Functions, amplitude against years, noting the percentage of accounted variance



effects, but the exact causes are still under debate. Therefore, this investigation only considers the effect of climate on wheat yield.

Figure 2b allow us to identify low yields in the years 1981, 1995, 2005, and 2012, which coincide with drier years (Vicente-Serrano et al. 2014), while high yields were observed for the years 2013, 2007, 1996, and 1988. Some of these features are reported in the JRC bulletins Centre (2014). For example, excellent positive conditions for wheat yield in Spain were noticed in 2013 with precipitation above-average and temperature below-average in May, what permitted the maintenance of sufficient soil moisture; the low wheat productivity in 2012 as consequence of above-average temperature and dry conditions in May and June.

To better understand the effects of monthly precipitation and temperature upon the overall yield, Fig. 4 compares the annual cycle of the variables Pr, Tmax, Tmin, and DTR for the years of high (low) wheat yield with respect the annual cycle for the entire period 1979 to 2014. The precipitation curve is above (below) the corresponding mean cycle for years with high (low) wheat yield, indicating the

positive (negative) effect of precipitation upon the yield for every month (Fig. 4a). However, regarding the influence of monthly temperatures, we can see how high maximum and minimum temperatures in spring may damage the yield and how high minimum temperature in winter provides favorable condition for the yield (Fig. 4c, d). It is interesting to note the negative effect of DTR on wheat yield for every month (Fig. 4b). Physiological processes of the plants depend on the sensible and latent heat. Sensible heat is related to solar radiation and Tmax during hours of sunshine, while at night is associated to the heat lost into space as infrared radiation and Tmin (Bristow and Campbell 1984). Our results indicate greater influence of DTR than Tmax and Tmin independently. DTR includes the effects of solar and terrestrial radiation, accounting for sensible heat across the day and representing both the frost risk in winter and heat stress in spring.

3.2 Effects of observed climate variables on wheat yield

As climate variables can affect wheat yield differently, depending on the season, we assessed the relationships

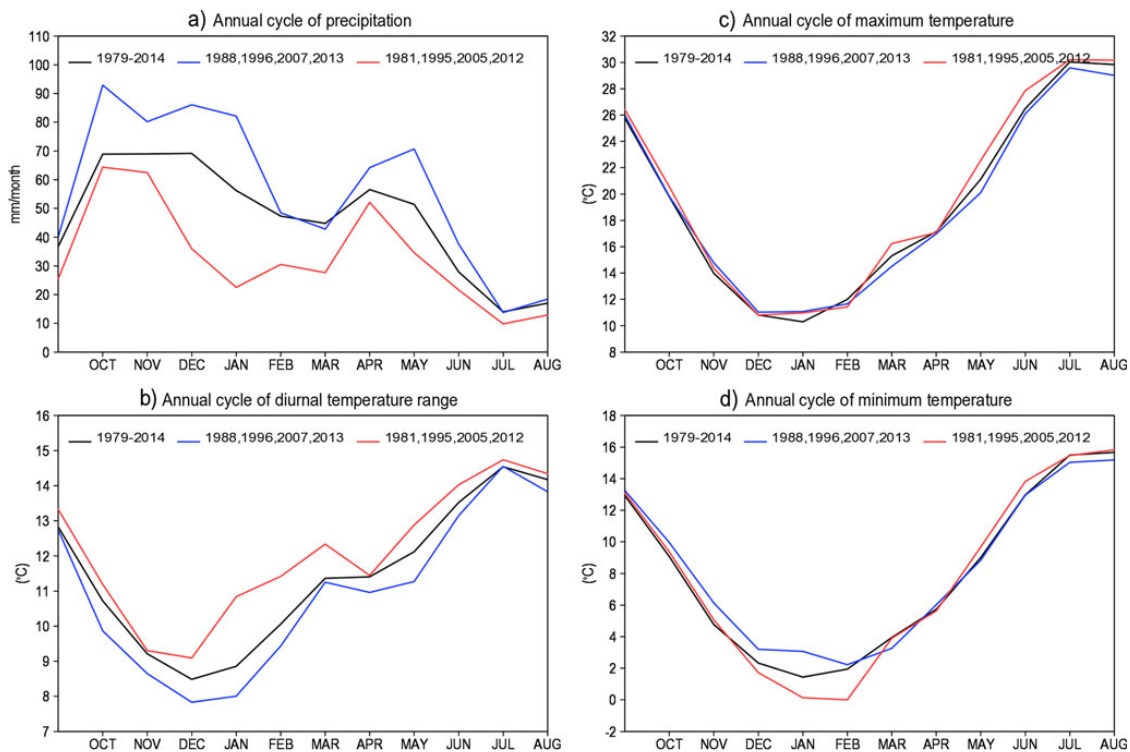


Fig. 4 a Seasonal cycle of precipitation (Pr); b diurnal temperature range (DTR); c maximum temperature (Tmax); d minimum temperature (Tmin). For the period 1979–2014 (black line), years of high wheat yield (blue), and years of low wheat yield (red)

between wheat yields and climate variables in different seasons autumn (SON), winter (DJF), and spring (MAM) covering the wheat crop from sowing to harvest. The first estimation for linking wheat yield to climate variation is deduced through the use of correlation maps between wheat time series and climate fields over Spain. Positive correlations were found in autumn and spring for standardized precipitation index (SPI_ SON and SPI_ MAM) (Fig. 5a, b), and in winter for minimum temperature (Tmin_ DJF) (Fig. 5e); negative correlation was found in spring for maximum temperature (Tmax_ MAM) (Fig. 5d) and in winter for diurnal range of temperature (DTR_ DJF) (Fig. 5c). The hatched areas in the correlation maps figures indicate when the correlation is higher than $|0.50|$.

Wheat yield is represented against the anomalies of spatially averaged climate time series of SPI, DTR, Tmax, and Tmin across Spain to assess the sensitivity of wheat yield to these climate variables, as the scatter plots of Fig. 5 show. SPI in MAM and in SON cause an increase in wheat yield, with greater sensitivity in MAM. Our empirical finding shows the damage of frost in winter and of heat in spring. These results are in agreement with previous studies (Rodríguez-Puebla et al. 2007) and with Gouache et al. (2015), which reported the importance of drought and heat stress in French yields during grain filling; Wu et al. (2014) also indicated the importance of rainfall in the spring. Frost and heat are reducing factors for crop yield. These processes are incorporated in some processed-based crop models (Challinor et al. 2005); however, their effects are not always well captured (Barlow et al. 2015). From our results, crop models could consider functions depending on DTR, accounting for frost and heat risk.

3.3 Variable selection and statistical model

We applied the PLS regression to identify the modes of climate variables that covariate with wheat yields. Conceptually, PLS determines the spatio-temporal modes of the climate variables that account for the maximum covariance between wheat yields and climate data. This method provides a dynamical adjustment for wheat yields using different climate variables. Figure 6 shows the spatial structures or patterns of the variables that are selected when the statistical model is applied; these include SPI in SON and MAM and DTR in DJF. The spatial patterns are characterized by correlating the component time series (B) with the corresponding climate fields (X), multiplied by 100. The hatched areas indicate when the correlation is higher than $|0.50|$ and associated statistical significance p test lower than 0.01. Figure 6a, b suggests the following interpretation: major yield is obtained when fewer drought events (SPI) occur in SON and MAM; the pattern accounts for 39 and 65 % of SPI variability, respectively. Figure 6c

indicates that lower values of DTR correlate with increases in wheat productivity in DJF; this mode accounts for 51 % of DTR variability. The derived adjustments from these climate variables are represented and quantified by the Pearson correlation coefficients, these are depicted in Fig. 6d–f, which show the sensitivity of detrended wheat yields in comparison with the representative indices or components (B) of the climate fields SPI in SON and MAM, and DTR in DJF. A comparison of Figs. 5 and 6 demonstrates the utility of the PLS method in characterizing climate effects on wheat yields since the PLS components of the different variables better represent the adjustment than the time series of the spatially averaged climate variables over Spain.

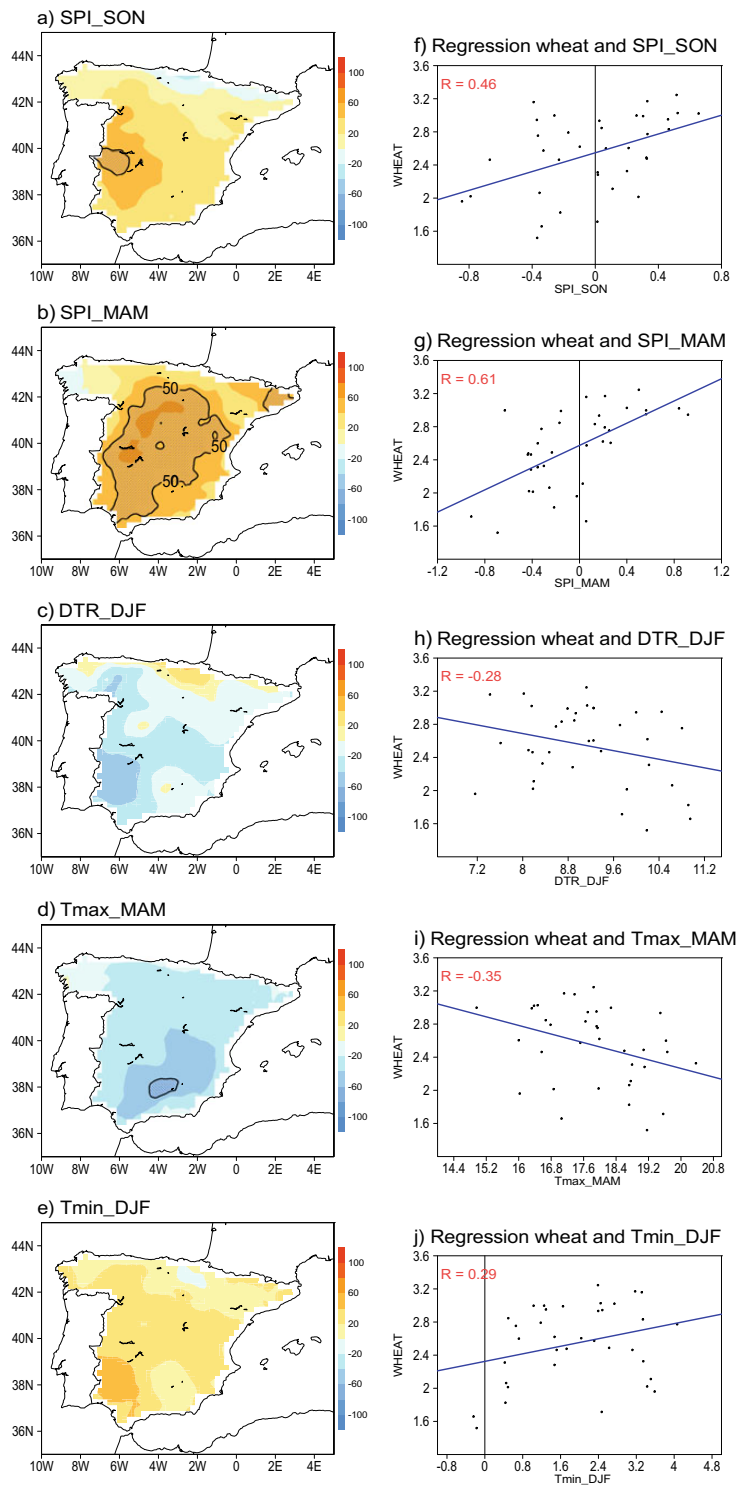
Initially, the potential predictors that have influence on wheat time series were SPI in SON and MAM, DTR in DJF and MAM, Tmin in DJF, and Tmax in MAM. By using the stepwise regression approach, the function identifies at each step terms to add to or remove, considering the criterion of minimizing the square error. Therefore, the variables selected were SPI in SON and MAM, and DTR in DJF. However, those climatic factors influencing wheat yield are often correlated with each other. The effect of Tmax in MAM is included by SPI, and the effect of Tmin is included by DTR in DJF. The model results are represented by Fig. 7; the adjustment describes the observed wheat yield fluctuations reasonably well, accounting for almost 63 % of wheat yield variability ($R = 0.82 \pm 0.06$). Yield is underestimated before 1985 and overestimated between 1985 and 1995. These results may be due to the fact that the model does not capture well the inter-decadal oscillation represented in Fig. 3c. The shaded areas represent the confidence interval of the results, indicating the uncertainty of the outputs. The error of the statistical model is quantified by the interval of the correlation coefficient, obtained using the bootstrap approach with 500 realizations. The statistical model is defined:

$$Y = 0.96 \cdot B(SPI_SON) + 0.94 \cdot B(DTR_DJF) + 1.44 \cdot B(SPI_MAM) \quad (2)$$

where Y represents wheat yield; $B(SPI_SON)$ and $B(SPI_MAM)$ are the representative indices of the variables SPI in autumn and spring; and $B(DTR_DJF)$ is the representative index of DTR in winter.

We obtained different drought effects according to the phases of the wheat’s growth, being higher during the maturity phases than at earlier stages. Some authors investigated the causes of production variation by their relationships to changes in phenology (Xiao et al. 2013; Tao et al. 2012; Li et al. 2015; Yu et al. 2014), in particular Oteros et al. (2015) studied the influence of rainfall on change in wheat phenology in Spain and pointed out the more marked changes in spring, what justify our findings.

Fig. 5 Correlation between the detrended wheat yield and climate variables, hatched areas when correlation is greater than 50 %; **a** SPI in autumn; **b** SPI in spring; **c** DTR in winter; **d** Tmax in spring; **e** Tmin in winter. Scatter plots of wheat yield versus: **f** SPI averaged in autumn and **g** in spring ; **h** DTR averaged in winter; **i** Tmax in spring; **j** Tmin in winter. R is the correlation of the regression equation



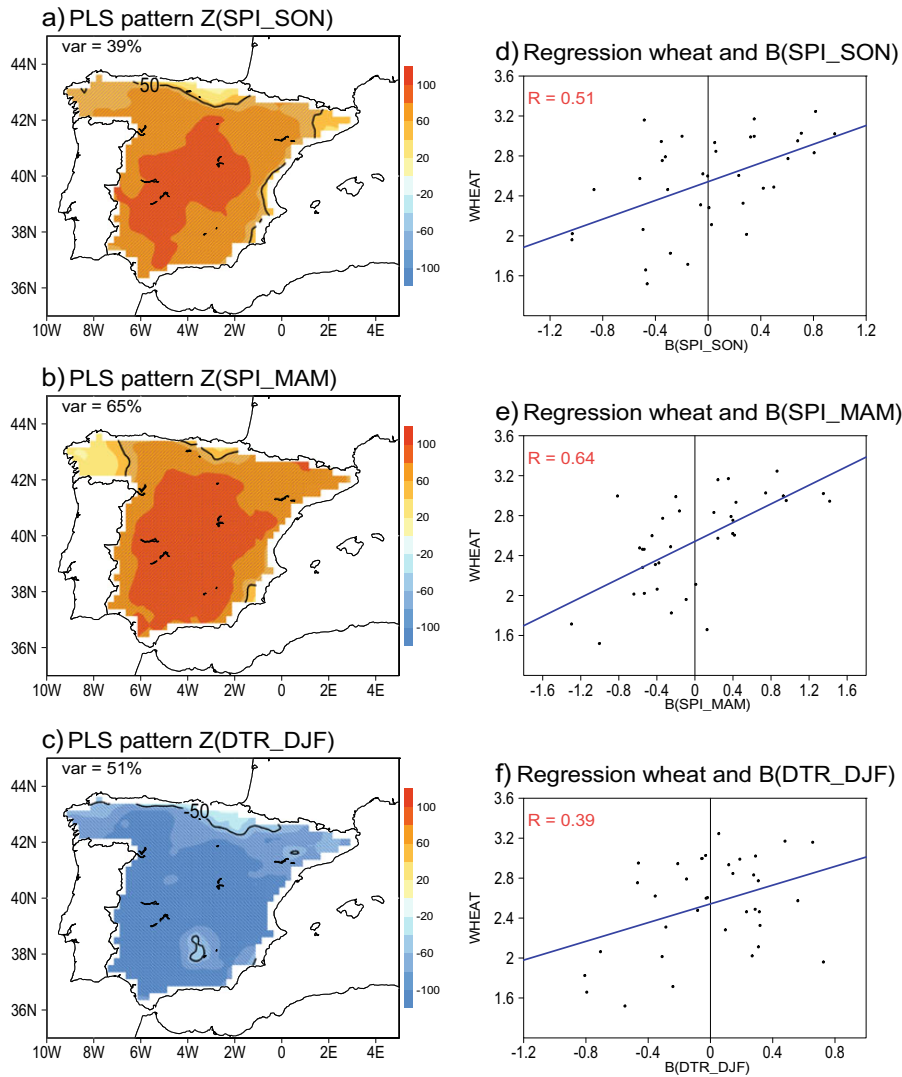


Fig. 6 Patterns of the partial least square regression derived between wheat time series and the climate fields; hatched areas when correlation is greater than 50%: **a** SPI in autumn; **b** SPI in spring; **c** DTR in

winter. Scatter plots of Wheat yield versus the representative indices of: **d** SPI in autumn; **e** SPI in spring; **f** DTR in winter

The increase of DTR in winter causes a reduction of wheat yield in Spain. In addition, we obtained the positive influence of the increase of Tmin in winter. Thereafter, this finding can justify the opposite relationships between DTR and wheat yield. However, in spring, the causes of the negative relationships between DTR and wheat yield are due to the higher increase of Tmax than Tmin. Tmax is responsible of heat stress. Although DTR is associated negatively with wheat yield in spring, it was not included in our model because its effect are represented by SPI.

3.4 Retrospective and Future wheat yield using CMIP5 models

Previous findings address the question regarding the impacts of climate change on wheat yields. To determine the projections of climate conditions and wheat yield in Spain, we examined the wheat yield results obtained by using GCMs outputs of CMIP5 models, in particular the variables specified in the agro-climate model, taking into account their relative importance (2).

Effects of diurnal temperature range and drought on wheat yield in Spain




Fig. 7 Time series of observed wheat yield (*black*) and results of empirical model (*red*); *grey* shading indicates the confidence interval. The correlation coefficient between both time series is 0.82 ± 0.06




Fig. 8 Trend time series of individual models and the Multimodel

When we implement the PLS regression in projecting wheat yields under climate change, the adjustment requires the consideration of spatial configurations or climate patterns associated with wheat yield, represented as dependent variable $Z(M)$, which were previously identified when the PLS regression was applied to the observations as it is explained in Section 3. The CMIP5 data of the same variable constitute the independent variables $X'(M, T)$. That is why, the PLS regression is applied to the spatial dimension instead of the temporal dimension, as was the case for the study with observations. The idea is to identify and capture structures from the CMIP5 data that resemble the ones found in the observed climate variables associated with wheat yield. This approach provides not only the structures but also the components of the PLS regression, which represents how these structures evolve over time. Therefore, to project wheat yield in different climate conditions, we suggest the use of the derived components (B') or the time series to build the statistical model.

The PLS regression is applied to the variables SPI in SON and MAM and DTR in DJF in each individual model. The derived time series are multiplied by the coefficients of the multivariate empirical agro-climate models, which estimated wheat yield for the observational period. We combined the wheat yield simulated by each model to compute the simulation of the multi-model. Here, we focus on the trend component of the individual models and the multi-model, which is isolated through the EEMD approach. Figure 8 shows the trend time series of different models, including the multi-model. Most of the models display a tendency towards wheat yield reduction; this trend is even more pronounced in the case of the multi-model for the entire period (1901–2099). However, the trend is not stationary, even showing an increase in some periods. Therefore, in Figure 9, we compare trends throughout the twentieth and twenty-first centuries, quantifying variations (T/ha in 100 years) through Sen’s estimator and gauging their significance with the Mann-Kendall Z test. For the twentieth century, the model CMCC-CESM displays a trend toward significant increase (when Z tests higher than |2|). Trends featuring a more dramatic decrease correspond to the model MIROC5 ($Z=-3.8$). For the twenty-first century,


the most significant decreasing trend corresponds to the model CanESM2, in accordance with the results showed by Fig. 8. In the case of the multi-model, our results indicate a decrease in wheat yield of $0.4T/ha$ for the period 1901 to 2000, which constitutes approximately 16 % of reduction. For the period from 2001 to 2099, a decrease of $0.8T/ha$ or about a 32 % reduction was observed.

In support of these results, we provided an estimation of the probability distribution in wheat yield with a box-and-whisker representation in Fig. 10, which compares observed wheat yields for individual models and the multi-model between periods of observation (1979–2014) and the

	a) Sen		b) Z	
CCSM4	-0.6	-1.2	-0.7	-2.3
CESM1-CAM5	-0.4	-0.7	-0.5	-1.9
CMCC-CESM	1.3	-1.1	2.0	-2.9
CNRM-CM5	-1.1	-0.9	-1.4	-1.4
CanESM2	0.6	-2.0	1.0	-3.6
GFDL-ESM2M	0.3	-0.3	0.4	-0.7
GISS-E2-H	0.0	-1.3	0.1	-2.2
HadGEM2-CC	-1.2	-0.6	-1.8	-0.9
HadGEM2-ES	-1.4	-0.9	-2.9	-1.8
MIROC5	-2.1	0.0	-3.8	0.1
MPI-ESM-MR	-0.6	-0.6	-1.0	0.0
NorESM1-M	-1.5	-0.9	-2.5	-1.7
MULTIM	-0.4	-0.8	-2.8	-4.1
	20	21	20	21

Fig. 9 **a** Wheat yield changes in the twentieth and twenty-first centuries assessed using Sen’s estimator; **b** Significance of the trend in the twentieth and twenty-first centuries as determined by using the Mann-Kendall Z test. Negative (positive) trend in *blue* (*red*) shading

Fig. 10 Box-and-whisker representation compares probability distribution of wheat yield for the periods 1979–2014 and 2070–2099. The *dot* indicates the position of the median, the *upper* and *lower lines* of the box correspond to the 75th and 25th percentiles, and the *topmost* and *bottommost lines* correspond to the extreme values. Negative values are changed to 0



corresponding future projection period (2070–2099). The dot represents the position of the median, the upper and lower lines of the box correspond to the 75th and 25th percentiles, and the topmost and bottommost lines correspond to the extremes values (negative values are changed to 0). The models that exhibit a greater reduction in the median are CanESM2, HadGEM2-CC, HadGEM2-ES, and NorESM1-M. However, the MIROC5 model indicates an increase in wheat yields at the end of twenty-first century. The multi-model predicts a decrease in the median, but similar variability in far future climate, compared to the observational period.

The mechanisms behind the projected changes in wheat yield are likely due to the evolution of the variables incorporated in the agro-climate model, such as SPI in SON, MAM, and DTR in DJF. Observations and model projections provide information about a trend towards a drier climate (IPCC 2013), and an increase of DTR in Spain (Franzke 2015), which may cause a reduction in wheat yields. Figure 11 depicts the evolution of SPI and DTR variables according to data obtained through the multi-model. We note a decreasing trend for SPI in SON and MAM, and an increasing trend for DTR in DJF, which support the observed decreased wheat yields due to the influence of SPI and DTR upon wheat growth.

4 Discussion

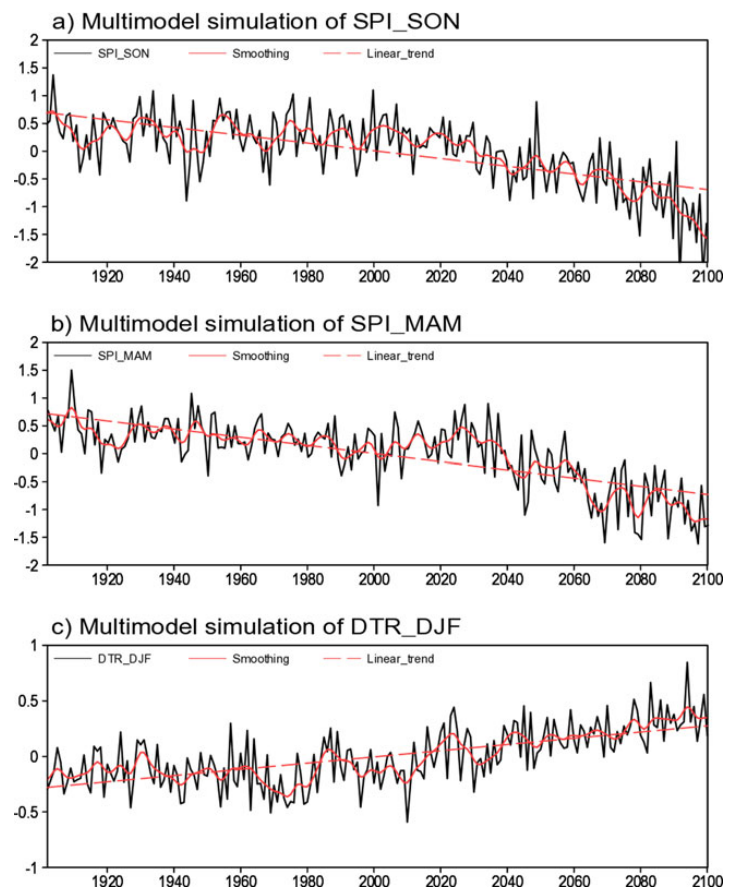
One of the main difficulties in obtaining the impact of climate change on crops in each region is to identify the driver variables due to their inter-relationships. In model, inter-comparison Rotter et al. (2011) reported deficiencies in descriptions related to extreme temperatures and drought.

Our analysis selects as relevant variables SPI and DTR, which are indirectly representing the effects of drought, heat, and frost risk on wheat variability. Drought in spring is the climate process most influential for wheat yield variability in Spain. The positive effect of precipitation on global wheat yields has been found by different authors (Challinor et al. 2014; Luo and Wen 2015). However, too much rainfall may affect negatively wheat (Rotter et al. 2013) and in some areas such as Scotland drier summers indicated a positive influence (Brown 2013).

DTR is a good indicator of climate change impact on wheat yield, since can characterize the frost and heat risk in Spain. However, these interpretations may vary for other latitudes such as in northern Europe, where an increased temperatures can prolong the vegetation period and reduce frost risk (Trnka et al. 2011a). Nevertheless, Chen et al. (2015) in China and Lobell (2007) in Australia and Canada obtained opposite relationships between DTR and crops. The negative response of Australian wheat yield to increase DTR was also reported by Nicholls (1997).

Wheat yield trends reveal a decrease in the twenty-first century in Spain if CO_2 effect is not taken into account. These findings are in accordance with other studies that project wheat yields using different approaches. Moore and Lobell (2014) reported a negative impact upon wheat yields throughout Europe as a result of future warming using empirical models. Process-based wheat models used by (Pirttioja et al. 2011) showed decreases in wheat yields over Europe assuming current CO_2 levels, with higher temperatures and decreased precipitation. These reductions may be due to the vulnerability of crops to extreme weather events, such as heat waves and drought (Coumou and Rahmstorf 2012; IPCC 2012; Trenberth 2012; Trnka et al. 2014; WMO 2013). Fertilization effects could be expected to rise from

Fig. 11 Multimodel simulation of the spatially averaged time series across Spain of: **a** SPI in SON, **b** SPI in MAM, and **c** DTR in DJF. *Black line* represents the simulated; the *solid red line* represents the 15-years smoothing, and the *dashed red line* indicates the linear trend



CO_2 increase. However, there is uncertainty in wheat yield simulated impacts with CO_2 : Supit et al. (2012) inform of wheat yield increase while (Asseng et al. 2013) and (Deryng et al. 2014) reported negative impact upon wheat yields throughout Europe under future warming. (Lobell and Gourdji 2012) also reported uncertainty about the interactions between elevated CO_2 and high temperature and the effect of CO_2 on the reduction of water stress. Since the relationships between wheat yield and climate may be non-stationary due to CO_2 effect on factors such as water-use efficiently, our model may be limited, as it does not take into account that the relationships between wheat and climate in present climate may change in future conditions. Otherwise, wheat projections may not be reliable because model data are uncertain (Knutti and Sedlacek 2013). Regarding the uncertainty of the models considered in this work, we first evaluated the precipitation and temperature against observations for the same period represented in the Taylor diagram. This indicates how closely the model and observation patterns correlate, which is also accomplished

by comparing the climographs showing the monthly averages of precipitation and temperature.

Figures S1 in the supplementary material include the Taylor diagram (Taylor 2001), for precipitation in SON and MAM, and maximum and minimum temperature in DJF, since these are the primary variables for deriving the SPI and DTR indices. Among the metrics used in the diagram are spatial correlation, standard deviation, and root-mean-square difference. For precipitation in SON, the models that closely agree with observation are CCSM4, CESM1-CAM5, HadGEM2-CC, and the Multi-model; for MAM, CCSM4, CESM1-CAM5, and the multi-model correlate most closely. For maximum temperature in DJF, better agreement is observed in the models CNRM-CM5, GISS-E2-H, and the Multi-model; minimum temperature in DJF shows better agreement for the models CCSM4, CNRM-CM5, and the Multi-model.

Additionally, Figure S2 in the supplementary material shows the climographs of the recorded observations and individual models, corresponding to the area of Spain for

the period 1979 to 2014. These climographs consider the agro-climate year, which begins in September and concludes in August. It was found that most models predict more precipitation than what is observed, with the exception of CMCC-CESM and CanESM2. The models that best represent the precipitation cycle are CESM1-CAM5, CCSM4, and HadGEM2-ES. The multi-model largely succeeds in representing the temperature progression but predict bias to higher levels of precipitation, mainly in summer. Despite the deficiencies of model data, we may have some confidence in the trend projections offered by the multi-model.

5 Conclusions

In this study, we have quantified the potential impacts of temperature extremes and precipitation deficit on overall wheat yield in Spain. In the interest of this goal, we applied different novel approaches, such as the partial least square regression and empirical mode decomposition. We obtained that precipitation deficit is more influential in autumn and spring, and DTR (sensible heat) is more influential in winter. The variability of both processes have been considered in our study to justify the variability of wheat yield by means of an empirical agro-climate model.

The performance of the model is measured in terms of the correlation coefficient obtained by regression between model results and the observed wheat yield. We found that climatic warming will cause a decrease in precipitation in spring and autumn and an increased diurnal range of temperature in winter for the twenty-first century throughout Spain. These changes will lead to a decrease in wheat yield, which is demonstrated through simulations of wheat yields using CMIP5 data. Here, we have analyzed climate effects on wheat yield, the individual models and the multi-model predict a decrease in wheat production in the twenty-first century at about a 32 % decline. These results are a simplification of the reality because this is a projection which does not take into account a potential CO_2 effect on crops. The future challenge entails ascertaining the effects of drought indices and large-scale patterns onto wheat yield variability by applying the PLS regression approach, which allows for progress in interpreting the relationships between climate processes and crop production variability.

Acknowledgments We acknowledge: the authors thank the reviewers for their helpful comments on the manuscript; the E-OBS dataset from the EU-FP6 project ENSEMBLES; the U.S. Department of Energy’s Program for Climate Model Diagnosis and Intercomparison provided CMIP5 data. Spanish Agriculture, Food and Environment (MAGRAMA) for crop data. We also acknowledge the developers of GrADS, CDO, NCL, and MATLAB software. This work was supported by the Ministry of Economy and Competitiveness of

Spain under National (CGL-2011-23209) and Regional (SA222A11-2) projects with FEDER European funds and fellowship BES-2012-054447 granted to S. Hernández-Barrera.

References

- Abdi H (2010) Partial least squares regression and projection on latent structure regression (pls regression). *WIREs Comput Stat*:1–10. doi:[10.1002/wics.051](https://doi.org/10.1002/wics.051)
- Angulo C, Rotter R, Lock R, Enders A, Fronzek S, Ewert F (2013) Implication of crop model calibration strategies for assessing regional impacts of climate change in Europe. *Agric For Meteorol* 170:32–46. doi:[10.1016/j.agrformet.2012.11.017](https://doi.org/10.1016/j.agrformet.2012.11.017)
- Asseng S, Ewert F, Rosenzweig C, Jones JW, Hatfield JL, Ruane AC, Boote KJ, Thorburn PJ, Rotter RP, Cammarano D, Brisson N, Basso B, Martre P, Aggarwal PK, Angulo C, Bertuzzi P, Biernath C, Challinor AJ, Doltra J, Gayler S, Goldberg R, Grant R, Heng L, Hooker J, Hunt LA, Ingwersen J, Izaurrealde RC, Kersebaum KC, Muller C, Kumar SN, Nendel C, O’Leary G, Olesen JE, Osborne TM, Palosuo T, Priesack E, Ripoche D, Semenov MA, Shcherbak I, Steduto P, Stockle C, Stratonovitch P, Streck T, Supit I, Tao F, Travasso M, Waha K, Wallach D, White JW, Williams JR, Wolf J (2013) Uncertainty in simulating wheat yields under climate change. *Nat Clim Chang* 3(9):827–832. doi:[10.1038/nclimate1916](https://doi.org/10.1038/nclimate1916)
- Atkinson MD, Kettlewell PS, Hollins PD, Stephenson DB, Hardwick NV (2005) Summer climate mediates UK wheat quality response to winter north atlantic oscillation. *Agric For Meteorol* 130(1-2):27–37. doi:[10.1016/j.agrformet.2005.02.002](https://doi.org/10.1016/j.agrformet.2005.02.002)
- Bannayan M, Lotfabad SS, Sanjani S, Mohamadian A, Aghaalkhani M (2011) Effects of precipitation and temperature on crop production variability in northeast Iran. *Int J Biometeorol* 55(3):387–401. doi:[10.1007/s00484-010-0348-7](https://doi.org/10.1007/s00484-010-0348-7)
- Barlow KM, Christy BP, O’Leary GJ, Riffkin PA, Nuttall JG (2015) Simulating the impact of extreme heat and frost events on wheat crop production: A review. *Field Crop Res* 171:109–119. doi:[10.1016/j.fcr.2014.11.010](https://doi.org/10.1016/j.fcr.2014.11.010)
- Beguieria S, Vicente-Serrano SM, Reig F, Latorre B (2014) Standardized precipitation evapotranspiration index (spei) revisited: parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. *Int J Climatol* 34(10):3001–3023. doi:[10.1002/joc.3887](https://doi.org/10.1002/joc.3887)
- Bristow KL, Campbell GS (1984) On the relationship between incoming solar-radiation and daily maximum and minimum temperature. *Agric For Meteorol* 31(2):159–166. doi:[10.1016/0168-1923\(84\)90017-0](https://doi.org/10.1016/0168-1923(84)90017-0)
- Brown I (2013) Influence of seasonal weather and climate variability on crop yields in Scotland. *Int J Biometeorol* 57(4):605–614. doi:[10.1007/s00484-012-0588-9](https://doi.org/10.1007/s00484-012-0588-9)
- Capa-Morocho M, Rodríguez-Fonseca B, Ruiz-Ramos M (2014) Crop yield as a bioclimatic index of el nino impact in Europe: Crop forecast implications. *Agric For Meteorol* 198:42–52. doi:[10.1016/j.agrformet.2014.07.012](https://doi.org/10.1016/j.agrformet.2014.07.012)
- Capparelli V, Franzke C, Vecchio A, Freeman MP, Watkins NW, Carbone V (2013) A spatiotemporal analysis of US station temperature trends over the last century. *J Geophys Res - Atmos* 118(14):7427–7434. doi:[10.1002/jgrd.50551](https://doi.org/10.1002/jgrd.50551)
- Carter TR (2013) Agricultural impacts multi-model yield projections. *Nat Clim Chang* 3(9):784–786
- Centre JR (2014) Mars bulletin vol.21. no6, 2013 and vol.20 no6, 2012. crop monitoring in Europe., <http://mars.jrc.ec.europa.eu/mars/Bulletins-Publications>
- Challinor AJ, Wheeler TR, Craufurd PQ, Slingo JM (2005) Simulation of the impact of high temperature stress on annual crop yields. *Agric For Meteorol* 135(1-4):180–189

- Challinor AJ, Watson J, Lobell DB, Howden SM, Smith DR, Chhetri N (2014) A meta-analysis of crop yield under climate change and adaptation. *Nat Clim Chang* 4(4):287–291. doi:[10.1038/nclimate2153](https://doi.org/10.1038/nclimate2153)
- Chen C, Zhou GS, Pang YM (2015) Impacts of climate change on maize and winter wheat yields in China from 1961 to 2010 based on provincial data. *J Agric Sci* 153(5):825–836. doi:[10.1017/s0021859614001154](https://doi.org/10.1017/s0021859614001154)
- Chen X, Wang M, Zhang Y, Feng Y, Wu Z, Huang NE (2013) Detecting signals from data with noise: theory and applications. *J Atmos Sci* 70(5):1489–1504. doi:[10.1175/jas-d-12-0213.1](https://doi.org/10.1175/jas-d-12-0213.1)
- Ciscar J, Soria A, Lavalle C, Raes F, Perry M, Nemry F, Demirel H, Rozsai M, Dosio A, Donatelli M, Srivastava A, Fumagalli D, Niemeyer S, Shrestha S, Ciaian P, Himics M, VanDoorslaer B, Barrios S, Ibanez N, Bianchi A, Dowling P, Camia A, Liberta G, San Miguel J, de Rigo D, Caudullo G, Barredo J, Paci D, Pycroft J, Saveyn B, VanRegemorter D, Revesz T, Vandyck T, Vrontisi Z, Baranzelli C, Vandecasteele I, BatistaSilva F, Ibarreta D (2014) Climate impacts in Europe. The jrc peseta ii project. Report, <http://www.jrc.ec.europa.eu>
- Colominas MA, Schlotthauer G, Torres ME (2014) Improved complete ensemble EEMD: A suitable tool for biomedical signal processing. *Biomedical Signal Processing and Control* 14:19–29. doi:[10.1016/j.bspc.2014.06.009](https://doi.org/10.1016/j.bspc.2014.06.009)
- Coumou D, Rahmstorf S (2012) A decade of weather extremes. *Nat Clim Chang* 2(7):491–496. doi:[10.1038/nclimate1452](https://doi.org/10.1038/nclimate1452)
- Dai A (2011) Drought under global warming: a review. *Wiley Interdiscip Rev Clim Chang* 2(1):45–65. doi:[10.1002/wcc.81](https://doi.org/10.1002/wcc.81)
- Dalla Marta A, Grifoni D, Mancini M, Zipoli G, Orlandini S (2011) The influence of climate on durum wheat quality in Tuscany, central Italy. *Int J Biometeorol* 55(1):87–96. doi:[10.1007/s00484-010-0310-8](https://doi.org/10.1007/s00484-010-0310-8)
- Deryng D, Conway D, Ramankutty N, Price J, Warren R (2014) Global crop yield response to extreme heat stress under multiple climate change futures. *Environ Res Lett* 9(3). doi:[10.1088/1748-9326/9/3/034011](https://doi.org/10.1088/1748-9326/9/3/034011)
- Eitzinger J, Thaler S, Schmid E, Strauss F, Ferrise R, Moriondo M, Bindi M, Palosuo T, Rotter R, Kersebaum KC, Olesen JE, Patil RH, Saylan L, Caldag B, Caylak O (2013) Sensitivities of crop models to extreme weather conditions during flowering period demonstrated for maize and winter wheat in Austria. *J Agric Sci* 151(6):813–835. doi:[10.1017/s0021859612000779](https://doi.org/10.1017/s0021859612000779)
- FAO (2014) Food agriculture organization of the united nations (FAO)., <http://faostat3.fao.org/compare/E>
- Feng J, Wu Z, Liu G (2014) Fast multidimensional ensemble empirical mode decomposition using a data compression technique. *J Clim* 27(10):3492–3504. doi:[10.1175/jcli-d-13-00746.1](https://doi.org/10.1175/jcli-d-13-00746.1)
- Flandrin P, Rilling G, Goncalves P (2004) Empirical mode decomposition as a filter bank. *IEEE Signal Process Lett* 11(2):112–114. doi:[10.1109/Asp.2003.821662](https://doi.org/10.1109/Asp.2003.821662)
- Franzke C (2010) Long-range dependence and climate noise characteristics of Antarctic temperature data. *J Clim* 23(22):6074–6081. doi:[10.1175/2010jcli3654.1](https://doi.org/10.1175/2010jcli3654.1)
- Franzke C (2015) Local trend disparities of european minimum and maximum temperature extremes. *Geophys Res Lett* (in press). doi:[10.1002/2015GL065011](https://doi.org/10.1002/2015GL065011)
- Gimeno L, Ribera P, Iglesias R, de la Torre L, Garcia R, Hernandez E (2002) Identification of empirical relationships between indices of ENSO and NAO and agricultural yields in Spain. *Clim Res* 21(2):165–172. doi:[10.3354/cr021165](https://doi.org/10.3354/cr021165)
- Gonsamo A, Chen JM (2015) Winter teleconnections can predict the ensuing summer European crop productivity. *Proc Natl Acad Sci USA* 112(18):E2265–E2266. doi:[10.1073/pnas.1503450112](https://doi.org/10.1073/pnas.1503450112)
- Gonzalez-Reviriego N, Rodriguez-Puebla C, Rodriguez-Fonseca B (2015) Evaluation of observed and simulated teleconnections over the Euro-Atlantic region on the basis of partial least squares regression. *Clim Dyn* 44(11–12):2989–3014. doi:[10.1007/s00382-014-2367-2](https://doi.org/10.1007/s00382-014-2367-2)
- Gouache D, Bouchon AS, Jouanneau E, Le Bris X (2015) Agrometeorological analysis and prediction of wheat yield at the departmental level in France. *Agric For Meteorol* 209:1–10. doi:[10.1016/j.agrformet.2015.04.027](https://doi.org/10.1016/j.agrformet.2015.04.027)
- Guan BT (2014) Ensemble empirical mode decomposition for analyzing phenological responses to warming. *Agric For Meteorol* 194:1–7. doi:[10.1016/j.agrformet.2014.03.010](https://doi.org/10.1016/j.agrformet.2014.03.010)
- Hansen JW, Jones JW, Irmak A, Royce F (2001) El Nino-Southern Oscillation impacts on crop production in the southeast United States, pp 55–76. *Asa Special Publication*
- Haylock MR, Hofstra N, Tank A, Klok EJ, Jones PD, New M (2008) A European daily high-resolution gridded data set of surface temperature and precipitation for 1950–2006. *J Geophys Res - Atmos* 113(D20):55–76. doi:[10.1029/2008jd010201](https://doi.org/10.1029/2008jd010201)
- Herrera S, Gutierrez JM, Ancell R, Pons MR, Frias MD, Fernandez J (2012) Development and analysis of a 50-year high-resolution daily gridded precipitation dataset over Spain (spain02). *Int J Climatol* 32(1):74–85. doi:[10.1002/joc.2256](https://doi.org/10.1002/joc.2256)
- Huang NE, Shen Z, Long SR, Wu MLC, Shih HH, Zheng QN, Yen NC, Tung CC, Liu HH (1998) The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proc R Soc Lond Series A Math Phys Eng Sci* 454(1971):903–995
- Iglesias A, Quiroga S (2007) Measuring the risk of climate variability to cereal production at five sites in Spain. *Clim Res* 34(1):47–57
- Iizumi T, Luo JJ, Challinor AJ, Sakurai G, Yokozawa M, Sakuma H, Brown ME, Yamagata T (2014) Impacts of El Nino Southern oscillation on the global yields of major crops. *Nat Commun*:5. doi:[10.1038/ncomms4712](https://doi.org/10.1038/ncomms4712)
- IPCC (2012) IPCC, 2012: Managing the risks of extreme events and disasters to advance climate change adaptation. A special report of working groups i and ii of the intergovernmental panel on climate change. In: Field CB, Barros V, Stocker TF, Qin D, Dokken DJ, Ebi KL, Mastrandrea MD, Mach KJ, Plattner G-K, Allen SK, Tignor M, Midgley PM (eds). Report, IPCC
- IPCC (2013) Climate Change 2013: the physical science basis. In: Stocker TF, Qin D, Plattner G-K, Tignor M, Allen SK, Boschung J, Nauels A, Xia Y, Bex V, Midgley PM (eds) Contribution of working group I to the fifth assessment report of the intergovernmental panel on climate change. Cambridge University Press, Cambridge
- IPCC (2014) Climate Change 2014: impacts, adaptation, and vulnerability. part a: global and sectoral aspects. In: Field CB, Barros VR, Dokken DJ, Mach KJ, Mastrandrea MD, Bilir TE, Chatterjee M, Ebi KL, Estrada YO, Genova RC, Girma B, Kissel ES, Levy AN, MacCracken S, Mastrandrea PR, White LL (eds) Contribution of working group II to the fifth assessment report of the intergovernmental panel on climate change. Cambridge University Press, Cambridge
- Jarlan L, Abaoui J, Duchemin B, Ouldouba A, Tourre YM, Khabba S, Le Page M, Balaghi R, Mokssit A, Chehbouni G (2014) Linkages between common wheat yields and climate in Morocco (1982–2008). *Int J Biometeorol* 58(7):1489–1502. doi:[10.1007/s00484-013-0753-9](https://doi.org/10.1007/s00484-013-0753-9)
- Ji F, Wu Z, Huang J, Chassignet EP (2014) Evolution of land surface air temperature trend. *Nat Clim Chang* 4(6):462–466. doi:[10.1038/nclimate2223](https://doi.org/10.1038/nclimate2223)
- Knutti R, Sedlacek J (2013) Robustness and uncertainties in the new CMIP5 climate model projections. *Nat Clim Chang* 3(4):369–373. doi:[10.1038/nclimate1716](https://doi.org/10.1038/nclimate1716)
- Li K, Yang X, Tian H, Pan S, Liu Z, Lu S (2015) Effects of changing climate and cultivar on the phenology and yield of winter wheat in the north China plain. *Int J Biometeorol* (in press). doi:[10.1007/s00484-015-1002-1](https://doi.org/10.1007/s00484-015-1002-1)

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

S. Hernandez-Barrera, et al.

- Lobell DB (2007) Changes in diurnal temperature range and national cereal yields. *Agric For Meteorol* 145(3–4):229–238. doi:10.1016/j.agrformet.2007.05.002
- Lobell DB (2013) Errors in climate datasets and their effects on statistical crop models. *Agric For Meteorol* 170:58–66. doi:10.1016/j.agrformet.2012.05.013
- Lobell DB, Burke MB (2010) On the use of statistical models to predict crop yield responses to climate change. *Agric For Meteorol* 150(11):1443–1452. doi:10.1016/j.agrformet.2010.07.008
- Lobell DB, Gourdji SM (2012) The influence of climate change on global crop productivity. *Plant Physiol* 160(4):1686–1697. doi:10.1104/pp.112.208298
- Lobell DB, Schlenker W, Costa-Roberts J (2011a) Climate trends and global crop production since 1980. *Science* 333(6042):616–620. doi:10.1126/science.1204531
- Lobell DB, Torney A, Field CB (2011b) Climate extremes in California agriculture. *Clim Chang* 109:355–363. doi:10.1007/s10584-011-0304-5
- Lorenzo-Lacruz J, Vicente-Serrano SM, Gonzalez-Hidalgo JC, Lopez-Moreno JJ, Cortesi N (2013) Hydrological drought response to meteorological drought in the Iberian peninsula. *Clim Chang* 58(2):117–131. doi:10.3354/cr01177
- Luo Q, Wen L (2015) The role of climatic variables in winter cereal yields: a retrospective analysis. *Int J Biometeorol* 59(2):181–192. doi:10.1007/s00484-014-0834-4
- MAGRAMA (2015) Spanish agriculture, food and environment department., <http://www.magrama.gob.es/estadistica/temas/estadisticas-agrarias/agricultura/avances-superficies-producciones-agricolas/>
- Moghtaderi A, Flandrin P, Borgnat P (2013) Trend filtering via empirical mode decompositions. *Comput Stat Data Anal* 58:114–126. doi:10.1016/j.csda.2011.05.015
- Moore FC, Lobell DB (2014) Adaptation potential of European agriculture in response to climate change. *Nat Clim Chang* 4(7):610–614. doi:10.1038/nclimate2228
- Moore FC, Lobell DB (2015) The fingerprint of climate trends on European crop yields. *Proc Natl Acad Sci USA* 112(9):2670–2675. doi:10.1073/pnas.1409606112
- Nicholls N (1997) Increased Australian wheat yield due to recent climate trends. *Nature* 387(6632):484–485
- Olesen JE, Trnka M, Kersebaum KC, Skjelvag AO, Seguin B, Peltonen-Sainio P, Rossi F, Kozyra J, Micale F (2011) Impacts and adaptation of European crop production systems to climate change. *Eur J Agron* 34(2):96–112. doi:10.1016/j.eja.2010.11.003
- Oteros J, García-Mozo H, Botey R, Mestre A, Galan C (2015) Variations in cereal crop phenology in Spain over the last twenty-six years (1986–2012). *Clim Chang* 130(4):545–558. doi:10.1007/s10584-015-1363-9
- Otkin J, Mark Shafer M, Svoboda M, Wardlow B, Anderson M, Hain C, Basara J (2015) Facilitating the use of drought early warning information through interactions with agricultural stakeholders. *Bull Am Meteorol Soc* 7:1073–1078. doi:10.1175/BAMS-D-14-00219.1
- Palosuo T, Kersebaum KC, Angulo C, Hlavinka P, Moriondo M, Olesen JE, Patil RH, Ruget F, Rumbaer C, Takac J, Trnka M, Bindi M, Caldag B, Ewert F, Ferrise R, Mirschel W, Saylan L, Siska B, Rotter R (2011) Simulation of winter wheat yield and its variability in different climates of Europe: a comparison of eight crop growth models. *Eur J Agron* 35(3):103–114. doi:10.1016/j.eja.2011.05.001
- Pirttioja N, Carter TR, Fronzek S, Bindi M, Hoffmann H, Palosuo T, Ruiz-Ramos MR, Tao F, Trnka M, Acutis M, Asseng S, Baranowski P, Basso B, Bodin P, Buis S, Cammarano D, Deligios P, Destain M, Dumont B, Ewert F, Ferrise R, Franois L, Gaiser T, Hlavinka P, Jacquemin I, Kersebaum KC, Kollas C, Krzyszczak J, Lorite JJ, Minet J, Minguez MI, Montesino M, Moriondo M, Mller CC, Nendel IO, Perego A, Rodriguez A, Ruane AC, Ruget F, Sanna M, Semenov MA, Slawinski C, Stratonovitch P, Supit I, Waha K, Wang E, Wu L, Zhao Z, Rötter RP (2011) Temperature and precipitation effects on wheat yield across a European transect: a crop model ensemble analysis using impact response surfaces. *Clim Res* 65:87105. doi:10.3354/cr01322
- Podesta G, Letson D, Messina C, Royce F, Ferreyra RA, Jones J, Hansen J, Liovet I, Grondona M, O’Brien JJ (2002) Use of ENSO-related climate information in agricultural decision making in Argentina: a pilot experience. *Agric Syst* 74(3):371–392. doi:10.1016/s0308-521x(02)00046-x
- Riahi K, Rao S, Krey V, Cho C, Chirkov V, Fischer G, Kindermann G, Nakicenovic N, Rafaj P (2011) Rcp 8.5-a scenario of comparatively high greenhouse gas emissions. *Clim Chang* 109(1–2):33–57. doi:10.1007/s10584-011-0149-y
- Rodriguez-Puebla C, Ayuso SM, Frias MD, Garcia-Casado LA (2007) Effects of climate variation on winter cereal production in Spain. *Clim Res* 34(3):223–232
- Rosenzweig C, Jones JW, Hatfield JL, Ruane AC, Boote KJ, Thorburne P, Antle JM, Nelson GC, Porter C, Janssen S, Asseng S, Basso B, Ewert F, Wallach D, Baigorría G, Winter JM (2013) The agricultural model intercomparison and improvement project (agmip): Protocols and pilot studies. *Agric For Meteorol* 170:166–182. doi:10.1016/j.agrformet.2012.09.011
- Rotter R, Hohn J (2015) Chapter 4: an overview of climate change impact on crop production and its variability in Europe, related uncertainties and research challenges, Food Agriculture Organization of the United Nations (FAO), Rome, 2011, Rome
- Rotter R, Ewert F, Palosuo T, Bindi M, Kersebaum K, Olesen J, Trnka M, van Ittersum M, Janssen S, Rivington M, Semenov M, Wallach D, Porter J, Stewart D, Verhagen J, Angulo C, Gaiser T, Nendel C, Martre P, de Wit A (2013) Challenges for agro-ecosystem modelling in climate change risk assessment for major European crops and farming systems. In: *Impacts World 2013 Conference Proceedings*, pp 555–564, DOI doi:10.2312/pik.2013.001, (to appear in print)
- Rotter RP (2014) Agricultural impacts robust uncertainty. *Nat Clim Chang* 4(4):251–252
- Rotter RP, Carter TR, Olesen JE, Porter JR (2011) Crop-climate models need an overhaul. *Nat Clim Chang* 1(4):175–177
- Royce FS, Fraisse CW, Baigorría GA (2011) ENSO classification indices and summer crop yields in the southeastern USA. *Agric For Meteorol* 151(7):817–826. doi:10.1016/j.agrformet.2011.01.017
- Ruiz-Ramos M, Sanchez E, Gallardo C, Minguez MI (2011) Impacts of projected maximum temperature extremes for C21 by an ensemble of regional climate models on cereal cropping systems in the Iberian peninsula. *Nat Hazards Earth Syst Sci* 11(12):3275–3291. doi:10.5194/nhess-11-3275-2011
- Schulzweida U (2015) CDO climate data operators, users guide., <https://code.zmaw.de/projects/cdo>
- Sen PK (1968) Estimates of regression coefficient based on Kendall’s Tau. *J Am Stat Assoc* 63(324):1379–1389
- Smoliak BV, Wallace JM, Stoelinga MT, Mitchell TP (2010) Application of partial least squares regression to the diagnosis of year-to-year variations in Pacific Northwest snowpack and atlantic hurricanes. *Geophys Res Lett*:37. doi:10.1029/2009gl041478.L03801
- Smoliak BV, Wallace JM, Lin P, Fu Q (2015) Dynamical adjustment of the Northern Hemisphere surface air temperature field: methodology and application to observations. *J Clim* 28(4):1613–1629. doi:10.1175/jcli-d-14-00111.1
- Supit I, van Diepen CA, de Wit AJW, Wolf J, Kabat P, Baruth B, Ludwig F (2012) Assessing climate change effects on European crop yields using the crop growth monitoring system and a weather generator. *Agric For Meteorol* 164:96–111. doi:10.1016/j.agrformet.2012.05.005

- Tao F, Zhang S, Zhang Z (2012) Spatiotemporal changes of wheat phenology in China under the effects of temperature, day length and cultivar thermal characteristics. *Europ J Agronomy* 43:201–212
- Taylor KE (2001) Summarizing multiple aspects of model performance in a single diagram. *J Geophys Res - Atmos* 106(D7):7183–7192
- Taylor KE, Stouffer RJ, Meehl GA (2012) An overview of CMIP5 and the experiment design. *Bull Am Meteorol Soc* 93(4):485–498. doi:10.1175/bams-d-11-00094.1
- Tian D, Asseng S, Martinez CJ, Misra V, Cammarano D, Ortiz BV (2015) Does decadal climate variation influence wheat and maize production in the Southeast USA? *Agric For Meteorol* 204:1–9. doi:10.1016/j.agrformet.2015.01.013
- Trenberth KE (2012) Framing the way to relate climate extremes to climate change. *Clim Chang* 115(2):283–290. doi:10.1007/s10584-012-0441-5
- Trenberth KE, Dai AG, van der Schrier G, Jones PD, Barichivich J, Briffa KR, Sheffield J (2014) Global warming and changes in drought. *Nat Clim Chang* 4(1):17–22. doi:10.1038/nclimate2067
- Trnka M, Eitzinger J, Semerádova D, Hlavinka P, Balek J, Dubrovsky M, Kubu G, Stepanek P, Thaler S, Mozny M, Zalud Z (2011a) Expected changes in agroclimatic conditions in central Europe. *Clim Chang* 108(1–2):261–289. doi:10.1007/s10584-011-0025-9
- Trnka M, Olesen JE, Kersebaum KC, Skjelvag AO, Eitzinger J, Seguin B, Peltonen-Sainio P, Rotter R, Iglesias A, Orlandini S, Dubrovsky M, Hlavinka P, Balek J, Eckersten H, Cloppet E, Calanca P, Gobin A, Vucetic V, Nejedlik P, Kumar S, Lalic B, Mestre A, Rossi F, Kozyra J, Alexandrov V, Semerádova D, Zalud Z (2011b) Agroclimatic conditions in Europe under climate change. *Glob Chang Biol* 17(7):2298–2318. doi:10.1111/j.1365-2486.2011.02396.x
- Trnka M, Roetter RP, Ruiz-Ramos M, Kersebaum KC, Olesen JE, Zalud Z, Semenov MA (2014) Adverse weather conditions for European wheat production will become more frequent with climate change. *Nat Clim Chang* 4(7):637–643. doi:10.1038/nclimate2242
- UCAR/NCAR (2015) The NCAR command language (software, version 6.3.0). <http://dx.doi.org/10.5065/D6WD3XH5>
- Vicente-Serrano SM, Cuadrat-Prats JM, Romo A (2006) Early prediction of crop production using drought indices at different time-scales and remote sensing data: application in the Ebro valley (north-east Spain). *Int J Remote Sens* 27(3):511–518
- Vicente-Serrano SM, Begueria S, Lopez-Moreno JI (2010) A multi-scalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index. *J Clim* 23(7):1696–1718. doi:10.1175/2009jcli2909.1
- Vicente-Serrano SM, Lopez-Moreno JI, Begueria S, Lorenzo-Lacruz J, Sanchez-Lorenzo A, Garcia-Ruiz JM, Azorin-Molina C, Moran-Tejeda E, Revuelto J, Trigo R, Coelho F, Espejo F (2014) Evidence of increasing drought severity caused by temperature rise in Southern Europe. *Environ Res Lett* 9(4):9. doi:10.1088/1748-9326/9/4/044001
- Wallace JM, Fu Q, Smoliak BV, Lin P, Johanson CM (2012) Simulated versus observed patterns of warming over the extratropical Northern Hemisphere continents during the cold season. *Proc Natl Acad Sci USA* 109(36):14:337–14:342. doi:10.1073/pnas.1204875109
- Watson J, Challinor AJ, Fricker TE, Ferro CAT (2015) Comparing the effects of calibration and climate errors on a statistical crop model and a process-based crop model. *Clim Chang* 132(1):93–109. doi:10.1007/s10584-014-1264-3
- White JW, Hoogenboom G, Kimball BA, Wall GW (2011) Methodologies for simulating impacts of climate change on crop production. *Field Crop Res* 124(3):357–368. doi:10.1016/j.fcr.2011.07.001
- Wilks D (2006) *Statistical methods in the atmospheric sciences*, 2nd edn. Academic
- WMO (2012) *Standardized precipitation index. User Guide*. Weather Climate Water, CH 1211 Geneva 2, Switzerland
- WMO (2013) *The global climate 2001–2010. A decade of climatic extremes. summary report*. Report
- Wold S, Sjostrom M, Eriksson L (2001) PLS-regression: a basic tool of chemometrics. *Chemom Intell Lab Syst* 58(2):109–130. doi:10.1016/s0169-7439(01)00155-1
- Wu J, Liu M, Lu A, He B (2014) The variation of the water deficit during the winter wheat growing season and its impact on crop yield in the north China plain. *Int J Biometeorol* 58(9):1951–1960. doi:10.1007/s00484-014-0798-4
- Wu Z, Huang NE, Long SR, Peng CK (2007) On the trend, detrending, and variability of nonlinear and nonstationary time series. *Proc Natl Acad Sci USA* 104(38):14:889–14:894. doi:10.1073/pnas.0701020104
- Wu ZH, Huang NE, Wallace JM, Smoliak BV, Chen XY (2011) On the time-varying trend in global-mean surface temperature. *Clim Dyn* 37(3–4):759–773. doi:10.1007/s00382-011-1128-8
- Xiao D, Tao F, Liu Y, Shi W, Wang M, Liu F, Zhang S, Zhu Z (2013) Observed changes in winter wheat phenology in the north China plain for 1981–2009. *Int J Biometeorol* 57(2):275–285. doi:10.1007/s00484-012-0552-8
- Xiao DP, Tao FL (2014) Contributions of cultivars, management and climate change to winter wheat yield in the north China plain in the past three decades. *Eur J Agron* 52:112–122. doi:10.1016/j.eja.2013.09.020
- Yu Q, Li L, Luo Q, Eamus D, Xu S, Chen C, Wang E, Liu J, Nielsen DC (2014) Year patterns of climate impact on wheat yields. *Int J Climatol* 34(2):518–528
- Yue S, Wang CY (2004) The Mann-Kendall test modified by effective sample size to detect trend in serially correlated hydrological series. *Water Resour Manag* 18(3):201–218. doi:10.1023/b:warm.0000043140.61082.60

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”

Supplementary Material

Effects of diurnal temperature range and drought on wheat yield in Spain

S. Hernandez-Barrera _ C. Rodriguez-Puebla _ A.J. Challinor

Table S1 Models from CMIP5 dataset used in our analysis

Model acronym	Model Name	Center	Resolution
CCSM4	Community Climate System Model, version 4	National Center of Atmospheric Research (NCAR), USA	0.9° (lat)x 1.25 (lon), L27
CESM1-CAM5	Community Earth System Model version 1 with the Community Atmospheric Model, version 5	National Science Foundation, U.S. Department of Energy, National Center for Atmospheric Research (NSF-DOE-NCAR), USA	0.9° (lat) x 1.25 (lon), L27
CMCC-CESM	Centro Euro-Mediterraneo per I Cambiamenti Climatici Carbon Cycle Earth System Model	Centro Euro-Mediterraneo per I Cambiamenti Climatici (CMCC), Italy	1.875° x 1.875° (T63), L95°
CNRM-CM5	Centre National de Recherches Météorologiques Coupled Global Climate Model, version 5	Centre National de Recherches Meteorologiques (CNRM-CERFACS), France	TL127, L31
CanESM2	Second Generation Canadian Earth System Model	Canadian Centre for Climate Modelling and Analysis (CCCMA), Canada	T63, L35
GFDL-ESM2M	Geophysical Fluid Dynamics Laboratory Earth System Model with Modular Ocean Model, version 4 (MOM4) component	NOAA Geophysical Fluid Dynamics Laboratory (NOAA-GFDL), USA	2.0°(lat) x2.5° (lon) M45, L24
GISS-E2-H	Goddard Institute for Space Studies Model E2, coupled with Hybrid Coordinate Ocean Model (HYCOM)	National Aeronautics and Space Administration (NASA) Goddard Institute for Space Studies, USA	2.0 (lat) x x2.5 (lon), L40
HadGEM2-CC	Hadley Centre Global Environment Model, version 2, Carbon Cycle	Met Office Hadley Centre (MOHC), UK	1.25° (lat) x 1.875 (lon), N96, L60
HADGEM2-ES	Hadley Centre Global Environment Model, version 2, Earth System	Met Office Hadley Centre (MOHC/INPE), UK	1.25° (lat)x 1.875 (lon), N96, L38
MIROC5	Model for Interdisciplinary Research on Climate, version 5	National Institute for Environmental Studies and Japan Agency for Marine-Earth Science and Technology, Japan	1.40625° x 1.40625°, T85, L40
MPI-ESM-MR	Max Planck Institute Earth System Model, medium resolution	Max Planck Institute for Meteorology, Germany	1.8° x 1.8°, T63, L95
NorESM1-M	Norwegian Earth System Model, version 1, intermediate resolution.	Norwegian Climate Centre (NCC), Norway	1.9°(lat) x 2.5°(lon), L26

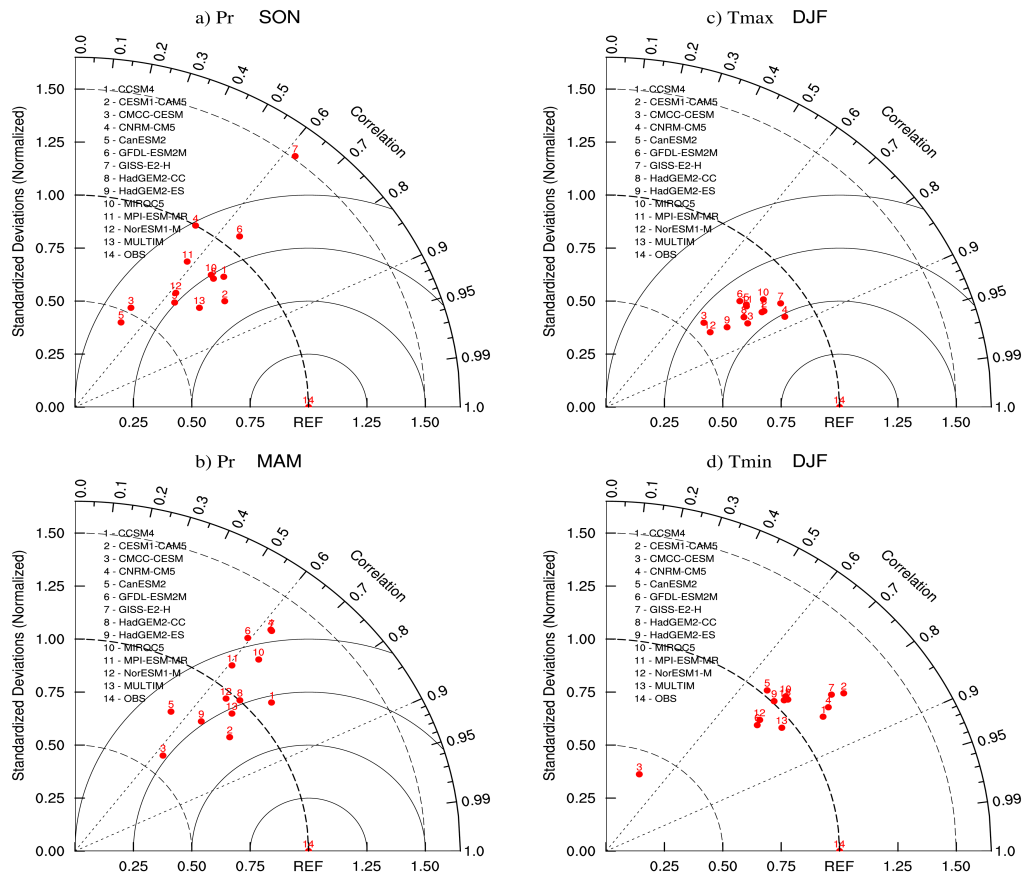


Fig. S1 Taylor diagrams for the period 1979-2014: **a)** precipitation (Pr) in SON; **b)** precipitation (Pr) in MAM; **c)** maximum temperature (Tmax) in DJF; **d)** minimum temperature (Tmin) in DJF. The numbers indicated the individual models, 13 corresponds to the Multimodel and 14 to the observation as reference (REF)

5.1. Artículo “Efectos del rango térmico diario y sequía en la productividad del trigo en España”




Fig. S2 Climographs for the period 1979-2014 in Spain, using models and observation (E-OBS). The blue bars represent mean monthly precipitations and the red line indicates the mean monthly temperature. The top numbers indicate the mean temperature (T_{mean}), seasonal range (T_{range}), and accumulated precipitation (Pr)

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

5.2.1. Resumen

La variabilidad y el cambio climático pueden tener impactos importantes en las producciones agrícolas. Por lo tanto, el objetivo de este estudio es investigar las proyecciones del rendimiento del trigo en un clima cada vez más cálido. Para abordar los objetivos, se determinan las relaciones entre el rendimiento del trigo en España y las variables a gran escala. Se aplicó la regresión por mínimos cuadrados parciales para determinar los modos de las variables climáticas que impulsan a la variabilidad del rendimiento del trigo, revelando una influencia significativa con la radiación solar incidente en la superficie terrestre. Para estimar la variabilidad interanual del trigo se determinaron modelos robustos basados en los patrones estacionales de la radiación solar. Se encontró que el rendimiento de los modelos basados en la radiación solar es mejor que el de los estudios anteriores, basados en precipitación y temperatura. De este modo, las simulaciones del proyecto de intercomparación de modelos acoplados de la fase 5 (CMIP5) se utilizan para proyectar las tasas del rendimiento del trigo bajo el calentamiento global, incorporando una estadística de reducción de escala directa. El rango esperado de la tendencia del rendimiento del trigo proyectado en el siglo XXI indica un descenso de un 6-8 % en España. Por lo que, los modelos sugeridos podrían aplicarse para la adaptación y la planificación.

Palabras clave: Modelo empírico de rendimiento del trigo · Rendimiento del trigo y radiación solar · Tendencia del rendimiento del trigo · Regresión por mínimos cuadrados parciales · Conglomerado de K-medias

5.2.2. Puntos de partida y recursos

Este artículo se planteó por la incertidumbre de las proyecciones del rendimiento de trigo dadas por los modelos empíricos que incluyen la variable

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

precipitación. Diferentes estudios (Wilby et al. 1998, Knutti & Sedlacek 2013, Baker & Taylor 2016) demuestran la imprecisión de los modelos CMIP5 en relación a las proyecciones de precipitación. De modo que, las cuestiones planteadas para desarrollar esta investigación fueron:

1. ¿Cuál es la asociación entre el rendimiento de trigo y las variables climáticas a gran escala?
2. ¿Son adecuados los modelos empíricos basados en variables a gran escala para simular el rendimiento de trigo?
3. ¿Se puede disminuir la incertidumbre de las tendencias proyectadas con modelos empíricos basados en variables a gran escala respecto a las variables regionales?

Para la ejecución de este estudio se utilizaron los siguientes datos: el rendimiento del trigo de 48 provincias de toda España para el periodo 1980-2014; datos de reanálisis para el periodo comprendido desde septiembre de 1979 hasta agosto de 2014. Se consideraron las variables de radiación solar en superficie (SSRD), la altura geopotencial al nivel de 500 hPa (Z500), la presión al nivel del mar (MSL) y el viento horizontal a 250 hPa (U250) pertenecientes al reanálisis ERA-Interim. Además, se utiliza la temperatura superficial del mar (SST) del reanálisis ERSST v3b para el mismo periodo que los datos del reanálisis ERA-Interim. Simulaciones de SSRD de 12 modelos CMIP5 (ver Capítulo 3) para el período 1901-2099, utilizando las simulaciones “Historical” y las “RCP8.5”. E índices de teleconexión, disponibles en ESRL de la NOAA.

Los métodos que se han aplicado para llevar a cabo este estudio son:

- ◇ Descomposición Empírica en modos por conjuntos (EEMD). Al igual que en el estudio anterior, se ha aplicado como un filtro de pasa alta para retener todas las IMFs excepto el residual de las series del rendimiento de trigo, y para obtener la componente de tendencia del rendimiento de trigo simulado a partir de los modelos CMIP5.
- ◇ Conglomerado K-medias (K-means) para agrupar los datos del rendimiento de trigo en regiones, considerando la variabilidad del trigo (ver Capítulo 4).
- ◇ Regresión por mínimos cuadrados parciales para obtener las señales de las variables a gran escala que explican la variabilidad del trigo. Del mismo

modo que se hizo en el estudio anterior, la regresión PLS se aplica de dos maneras diferentes. Primero, se aplica para obtener los modos estadísticos de las variables a gran escala asociadas con el rendimiento del trigo observado. A diferencia del estudio previo, en este caso se han introducido dos variables dependientes, que corresponden con los rendimientos de trigo sin tendencia de las dos regiones identificadas con el método K-mean. Las variables independientes son las variables a gran escala del reanálisis. Además, se evalúa la calidad de respuesta proporcionando la varianza descrita por las componentes PLS en las variables dependientes e independientes y el RMSE. Estas componentes PLS se utilizan para estimar el modelo agroclimático empírico mediante la regresión paso a paso (ver Capítulo 4), de la misma manera que en el estudio anterior. En el segundo paso, se aplicó la regresión PLS en el modo espacial para derivar la variabilidad de estos modos correspondientes a los datos CMIP5. En este caso, las variables independientes son las simulaciones de CMIP5 y las variables dependientes son los patrones espaciales de los modos de gran escala identificados en el periodo observacional. Las series temporales derivadas del PLS se estandarizan y se ponderan con los coeficientes de regresión correspondientes al modelo empírico con el fin de proyectar el rendimiento de trigo en escenarios de cambio climático. Este procedimiento se lleva a cabo con cada modelo CMIP5 antes de calcular el multimodelo.

5.2.3. Discusión y conclusiones

Clasificación del rendimiento del trigo. El modelo agroclimático obtenido en el estudio anterior (Hernández-Barrera et al. 2016) recoge bastante bien el comportamiento del rendimiento de trigo a nivel nacional. Sin embargo, a la hora de reconstruir el trigo provincialmente con este modelo, los resultados indicaron que el modelo no era adecuado. Por esta razón, se decidió agrupar el rendimiento de trigo por regiones para reducir los errores en la estimación del rendimiento de trigo a nivel provincial, al igual que hizo Conradt et al. (2016) para el trigo de invierno en Alemania. Para ello, aplicamos K-means, el cual identifica dos regiones mostradas en la Figura 3.1 del Capítulo 3, donde las áreas coloreadas señalan los dos grupos en los que se clasificó el rendimiento de trigo de las provincias. De manera que, la frecuencia relativa de las áreas per-

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

tenecientes a cada grupo es del 55 % para la región 1 y del 45 % para la región 2. Además, esta figura muestra el rendimiento medio del trigo (en números negros) y el coeficiente de variación (en números azules) en las diferentes provincias. Se observa que la mayor variación del rendimiento de trigo corresponde a la meseta central, al contrario que en las zonas costeras donde se produce una menor variación.

Efectos de las variables a gran escala. En esta investigación, la regresión PLS se ha utilizado porque no sólo reduce la dimensionalidad, como es el caso del análisis EOF¹ aplicado en los estudios de Rodríguez-Puebla et al. 2007 y Cantelaube et al. 2004, sino que también proporciona la co-variabilidad entre el rendimiento de trigo y las variables a gran escala. En este caso, se aplica individualmente a cada campo climático, reteniendo sólo una componente. Las variables dependientes son las dos series temporales de rendimiento de trigo correspondientes a cada región. Y los predictores potenciales son las variables MSL, Z500, U250, SSRD y SST en diferentes estaciones, considerando el otoño (SON) del año anterior, y el invierno (DJF) y la primavera (MAM) del mismo año de la cosecha del trigo. Entre todas las variables a gran escala, la variabilidad de la SSRD explica la mayor varianza de los datos históricos del rendimiento de trigo, conteniendo el 62 %, 65 % y 63 % en SON, DJF y MAM, respectivamente, como se muestra en la Tabla 5.1. Además, la SSRD de SON, DJF y MAM son las variables seleccionadas por el modelo empírico.

Tabla 5.1: Evaluación de las relaciones de modelado a través de: la varianza de las variables independientes (Var X: SSRD, SST, Z500 y U250) y la varianza de la variable dependiente (Var Y: rendimiento de trigo); del coeficiente de determinación antes (R^2) y después (R^2_{CV}) de aplicar la validación cruzada; y de la raíz cuadrada del error cuadrático medio (RMSE) de la regresión PLS

	Var X (%)	Var Y (R^2) (%)	R^2_{CV} (%)	RMSE
PLS_SSRD_SON	5	62	58	0.11
PLS_SSRD_DJF	6	65	61	0.11
PLS_SSRD_MAM	7	63	58	0.11
PLS_SST_ATL_DJF	18	27	18	0.15
PLS_SST_ATL_MAM	24	20	13	0.16
PLS_Z500_MAM	16	31	24	0.15
PLS_U250_MAM	17	36	30	0.14

¹Acrónimo del término inglés Empirical Orthogonal Functions.

La Figura 5.9 muestra los modos espaciales de la SSRD de SON, DJF y MAM obtenidos mediante la regresión PLS, los cuales producen un centro de acción positivo en la Península Ibérica. Asimismo, se representan las componentes PLS correspondientes, junto con las series del rendimiento de trigo de cada región (barras), observándose que las componentes PLS de radiación ejercen un efecto negativo sobre el rendimiento de trigo.

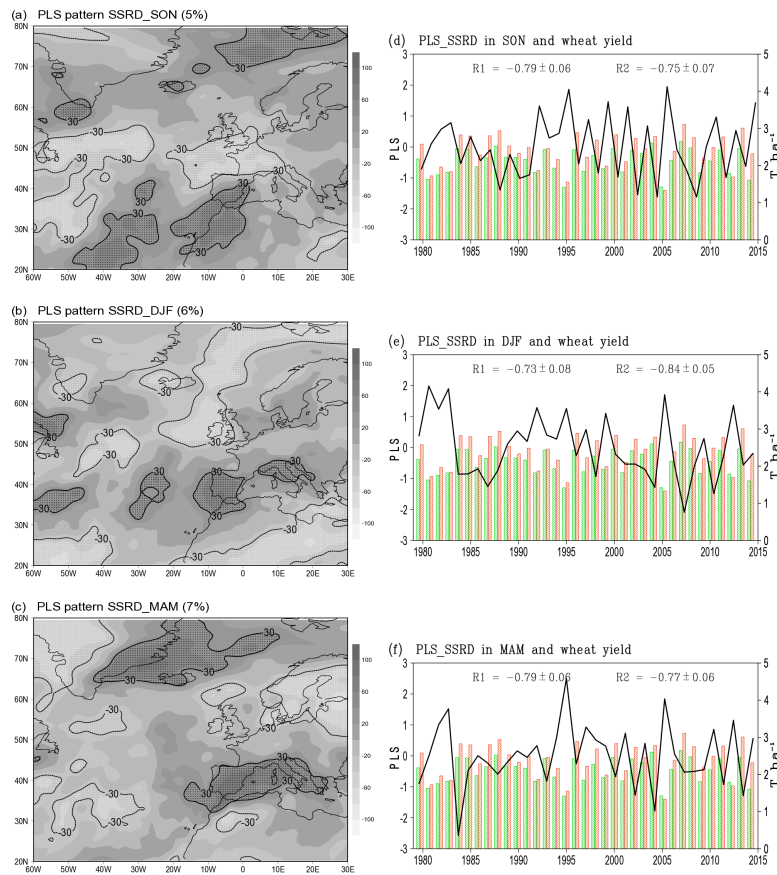


Figura 5.9: Patrones de la regresión PLS (a-c) derivados de las series temporales de trigo y los campos de la SSRD. Los patrones representan la correlación (%) entre la componente PLS y el campo SSRD donde las áreas punteadas indican una correlación superior del 30%.

Las componentes PLS de SSRD están representadas en las figuras d-f mediante líneas negras, las barras representan las series temporales del rendimiento de trigo espacialmente promediado en las dos regiones. R1 y R2 se refieren a los coeficientes de correlación entre las series temporales de las regiones 1 y 2

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

Modelo empírico. A partir de los predictores potenciales y mediante la regresión paso a paso (ver Capítulo 4) se obtiene el modelo que estima el rendimiento de trigo, del mismo modo que en el estudio anterior. La combinación óptima de predictores, seleccionada por la regresión paso a paso, está formada por las componentes PLS de la SSRD en las tres estaciones, es decir, en SON, DJF y MAM. Por lo tanto, el modelo empírico se describe de la siguiente manera:

$$Y = a \cdot PLS_SSRD_{SON} + b \cdot PLS_SSRD_{DJF} + c \cdot PLS_SSRD_{MAM} \quad (5.2)$$

donde Y corresponde con el rendimiento de trigo de cada región; PLS_SSRD_{SON} , PLS_SSRD_{DJF} y PLS_SSRD_{MAM} son las componentes PLS asociadas a los modos de la SSRD en otoño, invierno y primavera, respectivamente. Este modelo no incluye otras variables a gran escala porque la circulación atmosférica y la SST responden a los cambios radiativos, de manera que existe una co-variabilidad con la SSRD. De manera que, la PLS_SSRD en primavera se correlaciona con la PLS_Z500 (-0.70 ± 0.09), la PLS_U250 (-0.73 ± 0.08), y la PLS_SST del Pacífico (0.52 ± 0.11) y la PLS_SSRD en invierno se correlaciona con PLS_SST en el área del Atlántico Norte (-0.57 ± 0.10). Además, este modelo basado en la SSRD incluye los efectos de las teleconexiones en el rendimiento del trigo. Estas relaciones se indican a través de los coeficientes de correlación entre las componentes PLS_SSRD y los índices de teleconexión. La componente PLS de SSRD en invierno está asociada con los índices de teleconexión de la NAO (0.54 ± 0.10) y el EA (-0.43 ± 0.16). La influencia de la NAO en el rendimiento del trigo ya ha sido indicada por Cantelaube et al. (2004) y Rodríguez-Puebla et al. (2007). La componente PLS de SSRD en primavera está correlacionada con el índice de SCAND (-0.48 ± 0.15), lo que concuerda con los resultados obtenidos sobre la producción de trigo en el sur de Europa y el patrón SCAND de Cantelaube et al. (2004). Y la componente PLS de SSRD en otoño muestra señales de la AMO (-0.24 ± 0.18). Por lo tanto, estos hallazgos contribuyen al conocimiento de cómo influyen los índices de teleconexión en el rendimiento del trigo.

En la Figura 5.10 se compara el rendimiento de trigo observado con el simulado, obtenido con el modelo empírico, en las regiones 1 y 2, donde las barras de error indican el intervalo de confianza al 95 % para las predicciones. Se observa que se presentan algunas diferencias regionales en la amplitud. Además, en la

Tabla 5.2 se muestran las métricas de los modelos para poder así corroborar su robustez, observándose que el modelo basado en SSRD representa mejor el rendimiento de trigo en la región 2 que en la región 1.

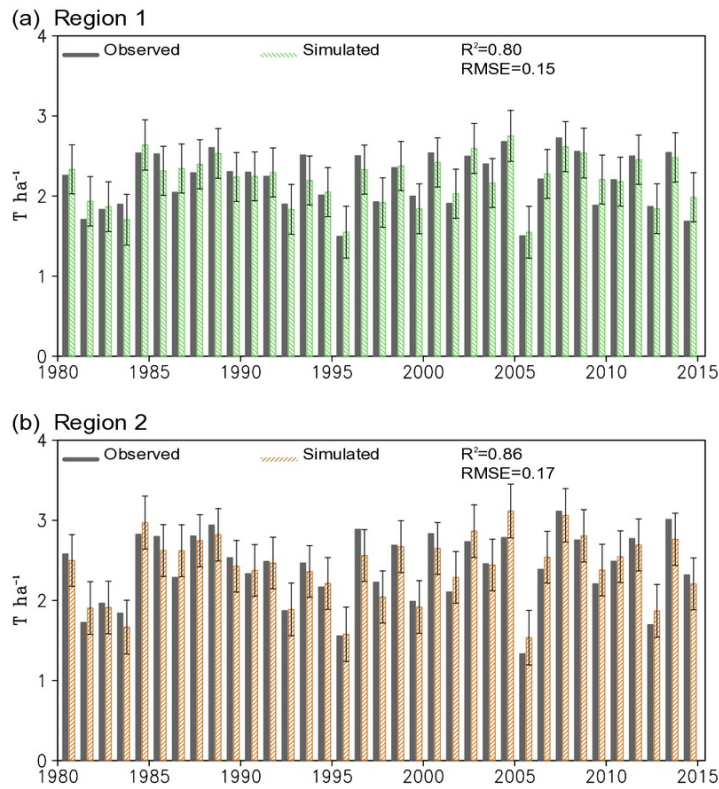


Figura 5.10: Series temporales del rendimiento de trigo observado (barra gris) y del rendimiento de trigo obtenido con los modelos empíricos para la región 1 (a) representado por barras verde y para la región 2 (b) representado por barras marrones, respectivamente. El intervalo de confianza del modelo viene dado por la barra de error, R^2 indica la varianza explicada por el modelo y RMSE la raíz cuadrada del error cuadrático medio

Tabla 5.2: Evaluación de las relaciones de modelado a través de: la varianza de las variables independientes (Var X: SSRD, SST, Z500 y U250) y la varianza de la variable dependiente (Var Y: rendimiento de trigo); del coeficiente de determinación antes (R^2) y después (R^2_CV) de aplicar la validación cruzada; y de la raíz cuadrada del error cuadrático medio (RMSE) de la regresión PLS

	R^2	R^2_CV	RMSE	DW	a	b	c
Región 1	0.813	0.795	0.153	2.2	$-0,129 \pm 0,040$	$-0,129 \pm 0,032$	$-0,103 \pm 0,041$
Región 2	0.877	0.859	0.165	2.0	$-0,123 \pm 0,043$	$-0,247 \pm 0,034$	$-0,118 \pm 0,044$

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

Para comprobar qué modelo representa mejor la variabilidad del rendimiento del trigo, se compara el modelo basado en la SSRD con el modelo basado en precipitación y temperatura en las dos regiones mediante un diagrama de dispersión, como se muestra en la Figura 5.11. Por lo tanto, el modelo que mejor bondad de ajuste presenta es el modelo basado en la SSRD. Además, para corroborar este hallazgo se realiza una comparación de los modelos locales a través del uso de mapas de correlación entre el rendimiento de trigo observado en cada provincia y el estimado por el modelo de SSRD, y el estimado por el modelo basado en SPI y DTR, el cual fue obtenido en el estudio previo como se muestra en la sección anterior. La significación del campo se determina mediante el estadístico FDR (ver Capítulo 4). Por lo que, el modelo que mayor confianza de campo muestra es el modelo basado en la SSRD, puesto que el 71 % de las provincias son significativas con el modelo basado en la SSRD y en el caso del modelo basado en SPI y en DTR, sólo, el 65 % son significativas. Por consiguiente, todos estos resultados indican que el modelo basado en SSRD presenta mejoras con respecto al modelo que considera el SPI y el DTR.




Figura 5.11: Diagrama de dispersión del modelo agroclimático basado en SSRD (línea negra) y del basado en SPI y DTR (línea azul) para la región 1 (a) y para la región 2 (b), respectivamente

Proyección del rendimiento del trigo utilizando modelos CMIP5. Basándonos en los hallazgos obtenidos previamente, las proyecciones del rendimiento de trigo basadas en la SSRD podrían reducir la incertidumbre de los modelos con respecto a proyecciones basadas en las variables regionales SPI y DTR. Por lo tanto, en este estudio se determinan las tendencias futuras del rendimiento del trigo en España bajo diferentes condiciones climáticas utilizando los patrones espaciales obtenidos de la regresión PLS para el período observacional y la variable de SSRD en SON, DJF y MAM de cada modelo CMIP5 para obtener las componentes PLS. Del mismo modo que se hizo en el

estudio previo, las series temporales derivadas se multiplican por los coeficientes del modelo empírico y se promedian para obtener el multimodelo, y así reducir el efecto de elección de las simulaciones de los modelos GCM² (Martre et al. 2015). Una vez obtenido el multimodelo, se procede con el aislamiento de las tendencias de los rendimientos de los modelos individuales y del multimodelo a través del método EEMD, las cuales se muestran en la Figura 5.12.

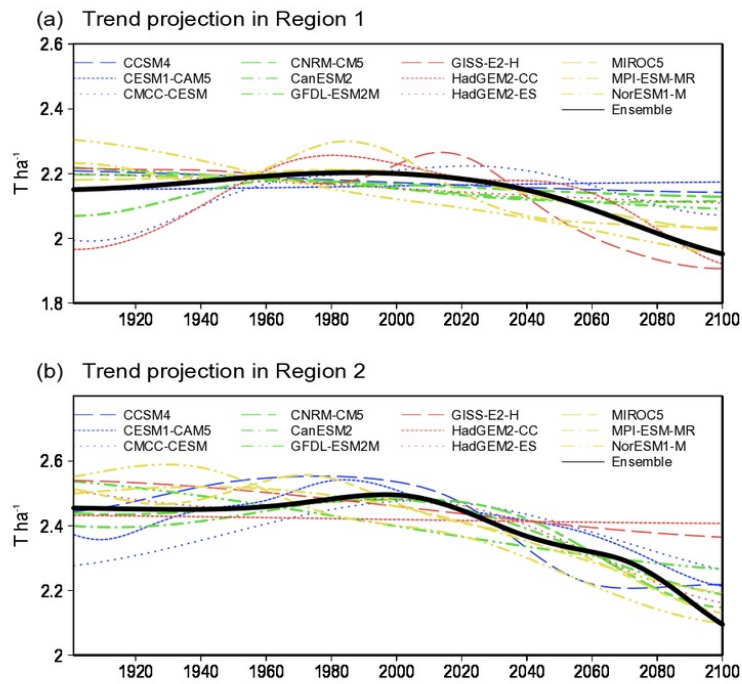


Figura 5.12: Series temporales de las tendencias filtradas del rendimiento de trigo simulado a partir de los modelos CMIP5 (línea de colores) y el multimodelo (línea negra): para la región 1 (a) y la región 2 (b), respectivamente

La mayoría de los modelos presentan una tendencia decreciente, siendo más pronunciada para el multimodelo. Sin embargo, comparando las tendencias de los experimentos “Historical” y “RCP8.5” se presentan algunas diferencias, mostrándose un aumento en algunos períodos. Por lo tanto, se comparan las tendencias a lo largo de los siglos XX y XXI (Figura 5.13) cuantificando las variaciones a través del estimador de Sen, y su significación con la prueba de Mann-Kendall Z (ver Capítulo 4). En el caso del multimodelo, estos resultados indican una disminución relativa con respecto al rendimiento medio del trigo de aproximadamente 6 % y 8 % en las regiones 1 y 2, respectivamente. De modo

²Acrónimo del término inglés General Circulation Model.

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

que, estos resultados son consistente con los obtenidos en el estudio mostrado en la sección 5.1, aunque en este caso la reducción sea mayor (32%). No obstante, estos resultados sugieren una disminución del rendimiento del trigo bajo condiciones de calentamiento. Sin embargo, la diversidad de valores que presentan las tendencias de los modelos podría deberse a la contribución de la variabilidad interna como indica Deser et al. (2014), lo que causa incertidumbre en la detección de tendencias. En este estudio, para cuantificar la contribución de la variabilidad forzada, con respecto a la variabilidad no forzada de los modelos, se obtuvo la relación señal/ruido (SNR) (González-Reviriego et al. 2015) (ver Capítulo 4). De manera que, la SNR para el siglo XXI es -1.47 para la región 1 y -1.42 para la región 2. Estos valores de SNR son mayores que los obtenidos con el modelo basado en SPI y DTR, que son -0.95 y -1.22 para las regiones 1 y 2, respectivamente. Estos resultados indican que la tendencia forzada debida al cambio climático es más robusta en el caso del modelo basado en SSRD, debido a que la SNR es mayor en valor absoluto.

(a) Region 1		Sen		Z Kendall	
CCSM4	0.07	-0.05	0.79	-0.66	
CESM1-CAM5	0.13	-0.18	2.20	-3.42	
CMCC-CESM	0.16	0.04	2.70	0.59	
CNRM-CM5	0.05	-0.21	0.74	-3.46	
CanESM2	0.09	-0.25	0.68	-3.44	
GFDL-ESM2M	0.01	-0.07	0.01	-1.24	
GISS-E2-H	0.13	-0.05	1.92	-0.44	
HadGEM2-CC	0.26	-0.17	3.91	-2.48	
HadGEM2-ES	0.07	-0.17	0.88	-3.18	
MIROC5	0.07	-0.09	2.45	-1.28	
MPI-ESM-MR	0.06	-0.13	1.03	-1.89	
NorESM1-M	-0.12	-0.11	-17.66	-1.73	
ENSEM	0.09	-0.12	4.13	-4.44	
	20	21	20	21	

(b) Region 2		Sen		Z Kendall	
CCSM4	0.08	-0.12	0.55	-1.25	
CESM1-CAM5	0.17	-0.36	2.21	-4.21	
CMCC-CESM	0.20	0.03	1.76	0.25	
CNRM-CM5	-0.01	-0.36	0.00	-3.48	
CanESM2	0.11	-0.41	0.77	-3.90	
GFDL-ESM2M	-0.05	-0.16	-0.57	-2.39	
GISS-E2-H	0.20	-0.02	1.86	0.04	
HadGEM2-CC	0.36	-0.27	3.15	-2.91	
HadGEM2-ES	0.04	-0.29	0.44	-4.36	
MIROC5	0.02	-0.15	0.33	-1.12	
MPI-ESM-MR	0.06	-0.11	0.76	-1.15	
NorESM1-M	-0.18	-0.28	-5.80	-3.00	
ENSEM	0.09	-0.19	2.69	-7.03	
	20	21	20	21	

Figura 5.13: Valores obtenidos del test del estimador de Sen (Sen) y del test de Mann-Kendall (Z) para evaluar los cambios en el rendimiento del trigo en los siglos XX y XXI obtenidos mediante los modelos CMIP5. Los valores de Sen y Z que indican tendencia significativa positiva (negativa) están sombreados en rojo (azul), respectivamente: para la región 1 (a) y para la región 2 (b)

Otra manera de obtener los cambios en el rendimiento de trigo, bajo condiciones de calentamiento, es comparando la distribución de probabilidad del rendimiento del trigo en diferentes períodos usando un diagrama de cajas. La Figura 5.14 muestra los resultados de los modelos individuales y del multimodelo para un período observacional (1980-2014) y para un período de proyección futura (2070-2099). Estos hallazgos predicen una disminución en la mediana

en todos los modelos, con la excepción del modelo CMCC-CESM, lo que está de acuerdo con el resultado anterior (Figura 5.13).

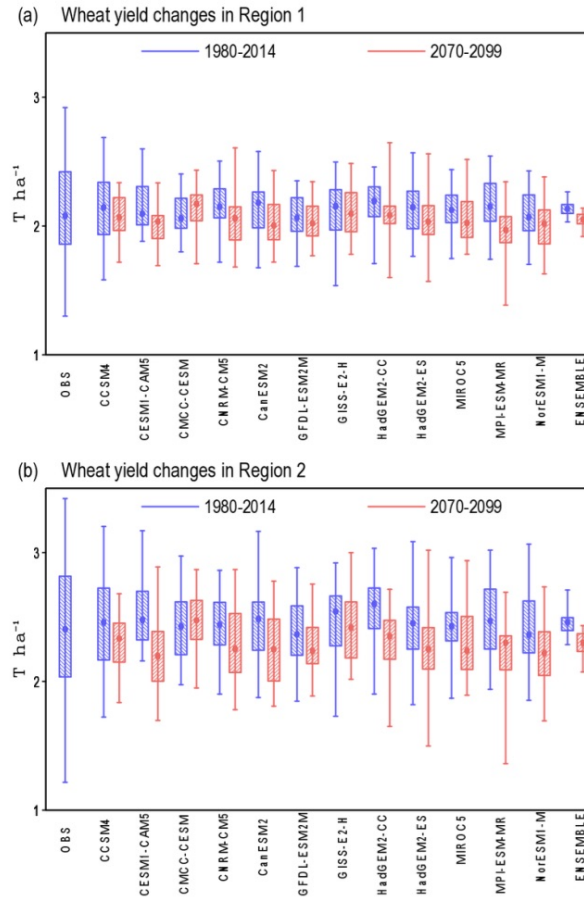


Figura 5.14: Diagrama de Cajas que compara los rendimientos de trigo obtenidos a partir de las salidas de los modelos CMIP5. En cada diagrama están representadas la distribución de probabilidad del rendimiento para el período de observación 1979-2014 (azul) y para el período de proyección 2070-2099 (rojo) para la región 1 (a) y para la región 2 (b)

Por lo tanto, la disminución del rendimiento de trigo podría verse forzado por el aumento de la radiación solar en España, es decir, se debe a los cambios producidos en la SSRD en SON, DJF y MAM. Este aumento en la radiación solar coincide con los resultados obtenidos por Sánchez-Lorenzo et al. (2013) y Wild (2016). No obstante, Chen et al. (2013) encontrarán que la disminución de la radiación, en China, tenía un impacto negativo en el rendimiento potencial del trigo. Así pues, las discrepancias entre los efectos de la radiación solar pueden deberse a diferencias climáticas regionales relacionados con la disponibilidad de agua. Por ejemplo en zonas húmedas el aumento de radiación solar

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

es favorable para el rendimiento de cultivos, pero en regiones secas el aumento de radiación acentúa la sequía y perjudica a las producciones.

5.2.4. Article “Wheat yield in Spain and associated solar radiation patterns” and Supporting Information

Wheat yield in Spain and associated solar radiation patterns

Sara Hernández-Barrera and Concepción Rodríguez-Puebla*

Department of Fundamental Physics, University of Salamanca, Spain

ABSTRACT: Climate variability and change can have important impacts for crop production. Therefore, the aim of this study is to investigate projections of the wheat yield in an increasingly warm climate. To address our objectives, we determined relationships between wheat yield in Spain and large-scale variables. Partial least squares regression was applied to determine the modes of the climate variables that drive wheat-yield variability, revealing a significant influence of surface solar radiation. Based on seasonal patterns of solar radiation, we determine models to estimate inter-annual wheat-yield variability. We find that the performance of the models based on solar radiation is better than that of earlier studies based on temperatures and precipitation variables. In this way, we use simulations of the Coupled Model Intercomparison Project Phase 5 (CMIP5) to project wheat-yield trend under warming climate by implementing direct statistical downscaling. The expected range of projected wheat yield trend for 21st century indicates decreases of about 6–8% across Spain. The suggested models could be applied for adaptation and planning.

KEY WORDS empirical wheat-yield model; wheat yield and solar radiation; wheat-yield trend; partial least square regression; *K*-mean cluster

Received 24 June 2016; Revised 28 November 2016; Accepted 2 December 2016

1. Introduction

Investigating the role of climate variability and change in crop productions is relevant both scientifically and socially (Lobell *et al.*, 2011; Lesk *et al.*, 2016). Process or statistical crop models are necessary to learn about the effects of climate on agriculture (Hansen *et al.*, 2006; Lobell and Burke, 2010; Ramirez-Villegas and Challinor, 2012; Asseng *et al.*, 2013; Lobell, 2013; Challinor *et al.*, 2014; Iizumi *et al.*, 2014a; Moore and Lobell, 2014; Ewert *et al.*, 2015; Watson *et al.*, 2015). The models are useful for analyzing the impact of climate change and for adapting strategies in the event of potential crop-yield losses (FAO, 2003; IPCC, 2014). In an earlier work (Hernandez-Barrera *et al.*, 2016, hereafter HB2016), we proposed a crop model to characterize wheat-yield variability based on historical data of seasonal drought and diurnal temperature range (DTR). We extrapolated this model to predict wheat yield in Spain for the 21st century using regional precipitation and temperatures produced by general circulation models (GCMs) and projected a reduction of about 32% over the country. According to Moore and Lobell (2015), climate trends can account for approximately 10% of the stagnation in European wheat. Our concern regarding the HB2016 study arises because simulated precipitation and temperatures from GCM are subject to great uncertainty and may cause biased of future crop trends (Mearns, 2003; Knutti *et al.*, 2008; Lobell and Burke, 2008; Asseng *et al.*,

2013). Therefore, with the aim of improving confidence in the wheat-yield projections, in this study we address directly downscaling the wheat yield using large-scale variables. Because regional climates respond to large-scale climate variables, we can expect wheat yield projections using large-scale predictors to be less uncertain than those obtained from the regional temperatures or precipitation provided by the GCMs (Wilby *et al.*, 1998; Knutti and Sedlacek, 2013; Baker and Taylor, 2016).

To determine the empirical wheat-yield model from the large-scale variables, we considered the following potential fields: surface solar radiation (SSRD), sea level pressure (MSL), geopotential height at 500 hPa (Z500), zonal wind at 250 hPa (U250) and sea surface temperature (SST). The effect of CO₂ was not included in this study because according to Nicholls (1997), it is insignificant when the wheat yield is de-trended. Although there is a broad understanding of the importance of solar radiation for crop productions due to the photosynthesis process, few studies have computed the observed relation between solar radiation and crop production. For example, Leng *et al.* (2016) obtained the relative contribution of solar radiation to corn and soybean in the United States, and Ceglar *et al.* (2016) analyzed the effect of solar radiation on winter wheat and maize yield in France. Trnka *et al.* (2007) compared the sensitivity of process-crop models to solar radiation. However, as far as we know, the modes of large-scale solar radiation have not been used empirically to determine wheat yield variability.

On the other hand, leading modes of atmospheric circulation were associated with wheat production in Europe by Cantelaube *et al.* (2004) with different influences

*Correspondence to: C. Rodríguez-Puebla, Departamento de Física Fundamental, Facultad de Ciencias, Plaza de la Merced s/n, 37008 Salamanca, Spain. E-mail: concha@usal.es

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

S. HERNÁNDEZ-BARRERA AND C. RODRÍGUEZ-PUEBLA

according to the country. Dalla Marta *et al.* (2011) found a correlation between durum wheat over Gibraltar and geopotential at 500 hPa. Through the use of teleconnection patterns, a number of studies have demonstrated that large-scale variables have effects on crop production. Thus, the El Niño Southern Oscillation (ENSO) and the North Atlantic Oscillation (NAO) have significant impacts on ecosystems worldwide (Stenseth *et al.*, 2003; Gonsamo and Chen, 2015), and they have been considered when analyzing the link with agricultural yields. For example, the ENSO has been used to analyze crop production: globally by Iizumi *et al.* (2014b); in Argentina by Podesta *et al.* (2002); and in Southeastern United States by Hansen *et al.* (2001), and Royce *et al.* (2011). The response of crops in Europe to the NAO was researched by Atkinson *et al.* (2005) in the UK, Orlandini *et al.* (2011) in the Mediterranean, and Gouveia *et al.* (2008) over the Iberian Peninsula. In Morocco, Jarlan *et al.* (2014) determined the association between wheat yield and the NAO and the ENSO. In Spain, Gimeno *et al.* (2002) identified relationships between the ENSO and the NAO with agricultural yield; Rodríguez-Puebla *et al.* (2007) found an association between winter cereal and the Southern Oscillation index, the Scandinavian and the NAO patterns; Capa-Morocho *et al.* (2016) found non-stationary relationships between El Niño and maize.

This paper is structured as follows: Section 2 presents the data and methods used, including the statistical approaches of partial least squares (PLS) regression, ensemble empirical mode decomposition (EEMD), and *K*-means cluster analysis. Section 3 presents the results of the model for two regions in Spain by aggregating the wheat yield from different provinces according to similarities of wheat variability. We use different statistical metrics to validate the robustness of the empirical model. Then, we apply the suggested statistical model to extrapolate the wheat yield using the simulated SSRD of 12 GCMs models from phase 5 of the Coupled Model Intercomparison Project (CMIP5). Section 4 discusses the results and draws conclusions, focussing on the comparison of projections based on downscaling from SSRD with those produced in the previous HB2016 study. In the Appendix S1, Supporting information we include some information and computations that complement our results.

2. Data and methods

2.1. Data

We make use of wheat yield (weight of production divided by the cultivation area in T ha^{-1}) provided for the Spanish Agriculture Food and Environment Department (MAGRAMA, 2015). The study area involved 48 provinces across Spain for the period 1980 to 2014 (Figure 1(a)). The trend of wheat yield corresponding to each province was filtered out, by applying the EEMD approach (Huang *et al.*, 1998) to perform the statistical analyses.

Reanalysis data are widely used for downscaling; we considered the following large-scale data from ECMWFs ERA-Interim reanalysis (Dee *et al.*, 2011): MSL; Z500; U250 and SSRD over the area between the latitudes and longitudes of 20°N – 80°N , 60°W – 30°E at the monthly time resolution for the period September 1979 to August 2014. We also used the SST data from the Extended reconstructed SST (ERSST v3b) (Smith *et al.*, 2008) over the Atlantic (0°N – 60°N , 60°W – 30°E) and Pacific (30°S – 30°N , 100°E – 60°W). These variables were linearly de-trended and weighted by the cosine of the latitude before the analyses were performed.

We also make use of GCMs simulations from 12 CMIP5 models, depicted in Table S1 in Appendix S1, to provide projections of the wheat yield under a warming climate. We performed the analyses with historical data from September 1901 to December 2005 and representative concentration pathway (RCP8.5) from January 2006 to August 2100 experiments (Taylor *et al.*, 2012). For methodological requirement, the model data were re-gridded to the same resolution of the reanalysis data by using the bilinear interpolation of the Climate Data Operators (CDO) software package (Schulzweida, 2015), and weighted by the cosine of the latitude in order to compensate for meridian convergence.

In addition to previous data, we have also used some teleconnection indices downloaded from the National Oceanic and Atmospheric Administration Earth System Research Laboratory (NOAA ESRL).

2.2. Ensemble empirical mode decomposition

Empirical mode decomposition (EMD) is a method for analyzing time series without linear or stationary assumptions (Huang *et al.*, 1998; Wu *et al.*, 2011). EMD decomposes a dataset into intrinsic mode functions (IMFs). This method has been modified to obtain better signal separation, known as the EEMD method (Chen *et al.*, 2013c), in which Gaussian white noise is added to each EMD process. EEMD was used in this work to separate the trend component of the observed wheat time series, after all the oscillatory components were removed from the time series. It also yields the scales of variability and the trend component of the wheat-yield simulated from the CMIP5 models. For a detailed description of the methods, we refer to our earlier work (HB2016).

2.3. *K*-means clustering

It is important to note that the aggregation of wheat yield would increase the goodness of the statistical model to fit the data as reported by Gornott and Wechsung (2016). Therefore, the wheat yield data were classified according to *K*-means cluster analysis. Our classification considered only wheat variability, which is different from the method used by Iglesias *et al.* (2000), who applied cluster analysis to group Spain into agro-climatic regions based on temperature and precipitation data. Other agro-climate classifications have considered yield in combination with topographical or soil characteristics (Yang *et al.*, 2006).

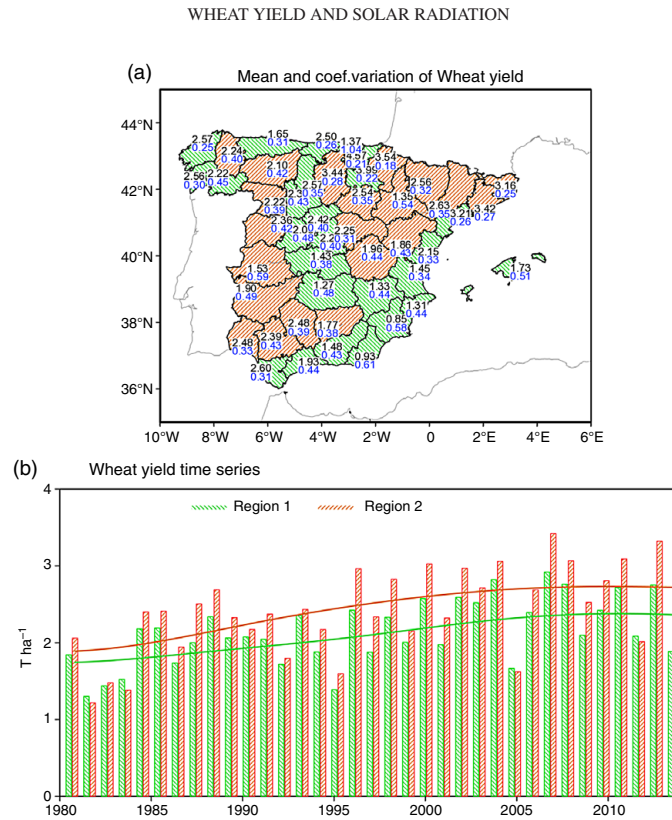


Figure 1. (a) Spatial distribution of wheat yield across Spain, top (bottom) numbers correspond to mean (coefficient of variation) values. The different pattern group areas with similar wheat-yield variability: region 1 (hatching diagonal downward lines) and region 2 (hatching diagonal upward lines). (b) Bars represent the time series of spatially averaged wheat yield in the two regions; lines correspond to the non-linear trend. [Colour figure can be viewed at wileyonlinelibrary.com].

K-means clustering aims to partition a given dataset into a number of clusters in which each cluster is determined by the degree of similarity and difference between observations. Here *K*-means clustering minimizes the squared Euclidean distance between the members of a given cluster and maximizes the distance between the centroids of the different clusters (Wilks, 2006). One problem encountered is determining the optimal number of clusters in advance. To overcome this limitation, we compared the outcomes of multiple runs with different *K*s and random noise generated from the data in order to obtain the best separation of the data. The silhouette criterion (Rousseeuw, 1987) and results of the function `evalcluster` of MATLAB allowed us to determine the optimal number of clusters (*K*), which the tests indicated as *K* = 2 (these evaluations are shown in Figures S1 and S2 in Appendix S1). It is important to note that the *K*-mean approach was applied to the de-trended wheat yield, weighted according to the surface it represented. Data of wheat yield at each province were assigned to a cluster, as shown in Figure 1(a) with the different patterns. The regional mean wheat yield enhanced relevant information for performing subsequent analyses. In our study, we applied *K*-means

clustering utilizing the MATLAB Statistical Toolbox and the International Research Institute (IRI) function, which perform the clustering in empirical orthogonal function (EOF) space by retaining a proportion of variance (Moron *et al.*, 2010).

2.4. Partial least squares regression

To obtain signals of the large-scale variables that covariate with wheat variability we applied the PLS regression approach (Rosipal and Kramer, 2006; Wold *et al.*, 2009).

As with EOF, PLS provides dimension reduction and, in addition, yields regression adjustment and covariance. First, we use PLS regression to obtain the statistical modes of the large-climate variables associated with the observed wheat yield. Second, we applied PLS regression in spatial mode to derive the variability of these modes corresponding to the CMIP5 data (Gonzalez-Reviriego *et al.*, 2015). In the first step, PLS regression utilized data from two sets of variables as inputs: independent variables (predictors) (i.e. the large-scale variables from reanalysis) and two dependent variables (i.e. the de-trended wheat yields averaged over the two regions identified with the cluster approach). The PLS regression produced spatial patterns

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

S. HERNÁNDEZ-BARRERA AND C. RODRÍGUEZ-PUEBLA

Table 1. Statistical metrics of wheat-yield time series for regions 1 and 2.

	Mean	STD	SK	KT	Sen	MK-Z
Region 1	2.12 ± 0.14	0.44 ± 0.04	-0.06 ± 0.45	-0.80 ± 0.59	0.26	3.6
Region 2	2.39 ± 0.19	0.57 ± 0.06	-0.26 ± 0.46	-0.70 ± 0.76	0.32	3.8

Mean ($T ha^{-1}$), STD, standard deviation ($T ha^{-1}$), SK, skewness; KT, kurtosis, Sen, trend changes ($T ha^{-1}$) in 10 years using Sen’s test; and MK-Z, trend significance using Mann–Kendal Z-test.

of the climate variables associated with wheat yield and the corresponding time series or PLS components that indicate the time evolution of the patterns. To evaluate the quality of the response, we provide the variance described by PLS components in the independent and dependent variables and the root mean square error (RMSE) of the residual. The PLS algorithm was used with cross-validation, leaving one-out data and the RMSE was computed from the average of all iterations.

In our case, the optimal number of PLS components was one of each field: Z500, U250, SSRD and SST. These standardized PLS components conform to the potential predictors used to estimate the empirical agro-climate model by applying stepwise linear regression (Wilks, 2006), which selects climate drivers to characterize wheat-yield variability. The procedure includes the variables, which are significant at a 95% level, and dismisses the effects’ co-variability among the variables. Cross-validation was applied as an indicator of the robustness of the model. The K -fold cross-validation produced a validation through the use of a multiple calibration/validation period combination. The model performance is characterized by the predicted R -squared coefficients and the residual RMSE corresponding to values predicted. These tests indicate how well a regression model predicts responses for new observations.

In the second step, PLS regression was applied to learn about the impact of climate change on wheat yield in Spain. In this case, the independent variables were the GCMs data of the CMIP5 simulations, and the dependent variables were the spatial patterns of the large-scale modes identified in the observational period. Therefore, the PLS method provided an estimation of the pattern evolution for CMIP5 data tailored to the corresponding observed patterns (Gonzalez-Reviriego *et al.*, 2015). To evaluate the stability of the pattern, bootstrap resampling method with replacement (Wilks, 2006) was applied to the individual CMIP5 simulations. The derived time series or simulated PLS components were standardized and weighted with the regression coefficients corresponding to the empirical model in order to project wheat yield under climate change scenarios. The procedure was carried out with each CMIP5 model. Note that we extrapolated the model of the present climate to future conditions and that this assumption may not hold for a warming climate. However, an ensemble multi-model of the results of every model was computed, providing their spread. From each simulation, we extracted the trend component by applying EEMD. The PLS regression and the statistical model were computed using packages included in the MATLAB and R Statistical

Table 2. Variance accounted for by the independent (VarX: SSRD, SST, Z500 and U250) and dependent (VarY: Wheat yield) variables.

	VarX (%)	VarY (R^2) (%)	R^2_{CV} (%)	RMSE
PLS_SSRD_SON	5	62	58	0.11
PLS_SSRD_DJF	6	65	61	0.11
PLS_SSRD_MAM	7	63	58	0.11
PLS_SST_ATL_DJF	18	27	18	0.15
PLS_SST_PAC_MAM	24	20	13	0.16
PLS_Z500_MAM	16	31	24	0.15
PLS_U250_MAM	17	36	30	0.14

R -squared before (R^2) and after (R^2_{CV}) cross-validation. Root mean squared error of the residuals (RMSE) of the PLS regression approach.

toolboxes. For a detailed description of the methods we refer to our earlier work (HB2016).

3. Results

3.1. Classification of wheat yield

The statistical model derived in HB2016 performed quite well in the case of the national aggregated wheat yield; however, when comparing the estimations with observations locally there was a decrease in its ability to reproduce the observations in some areas. In this way, the statistical model should be adapted locally due to different response of wheat yield to the DTR and the standardized precipitation index (SPI). These unclear discrepancies complicated the estimation of wheat-yield projection. To conduct our research, and consistent with Conradt *et al.* (2016) in the case of winter wheat in Germany, we gathered the wheat yield of the provinces into regions to reduce errors in the estimation of crop yield. K -means clustering identified the two regions specified in Figure 1(a), which shows mean wheat yield (top numbers) and the coefficient of variation (bottom numbers), or standard deviation normalized by the mean, in different provinces in Spain. Overall, greater wheat-yield variation corresponds to the central plateau and lesser variation corresponds to coastal provinces. The hatched areas denote the two clusters into which wheat yield of the provinces were classified. The relative frequency of the areas belonging to each cluster is 55% for region 1 and 45% for region 2. A comparative analysis of cluster performance is included in the Appendix S1.

Table 1 shows statistic metrics of the wheat yield time series of regions 1 and 2 before being de-trended: mean, standard deviation, skewness, trend change using the Sen’s estimator (Sen, 1968) and trend significance by

WHEAT YIELD AND SOLAR RADIATION

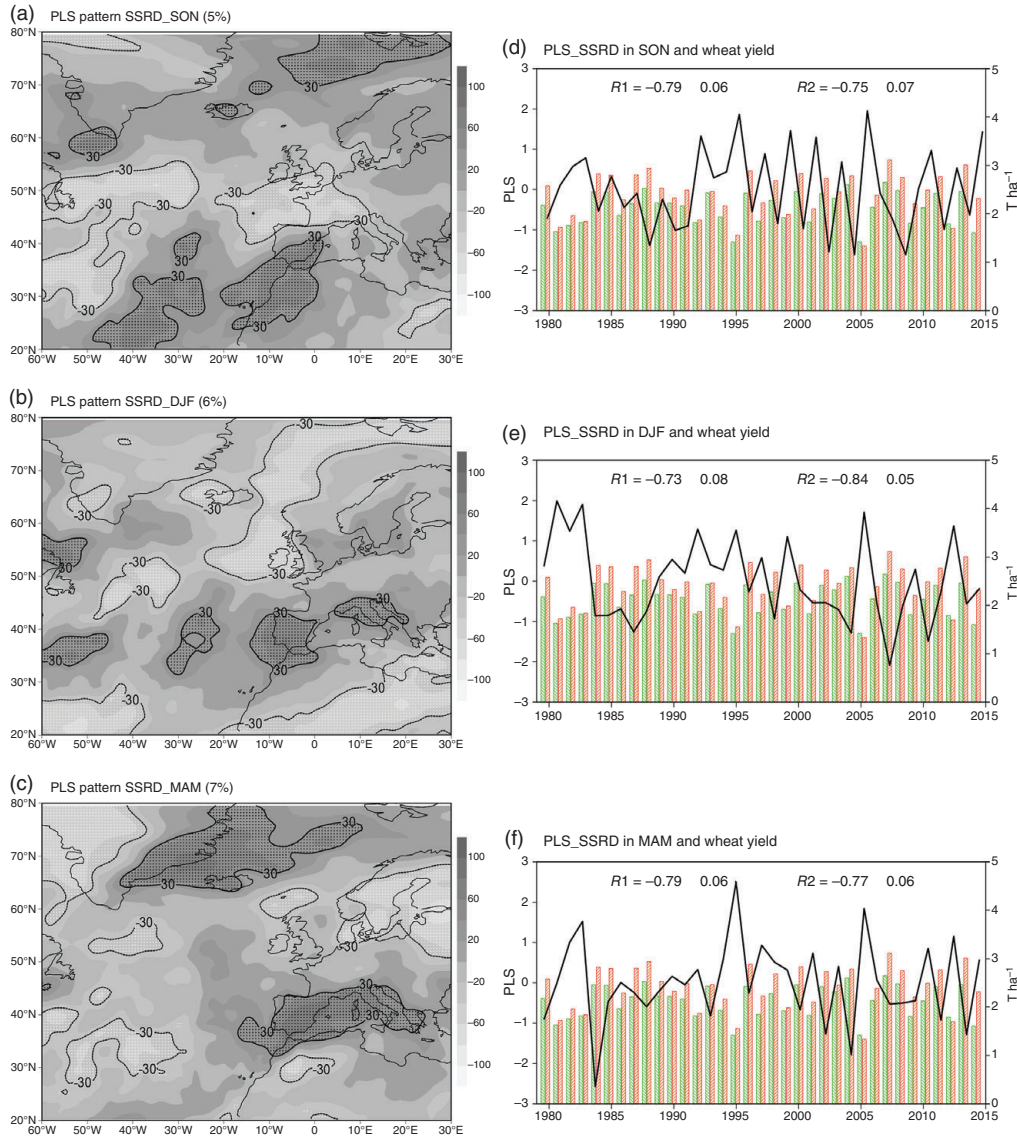


Figure 2. (a–c) Patterns of PLS regression derived between wheat time series and the SSRD fields; the patterns are given by the correlation (in %) between the PLS component and the SSRD field; dotted areas indicate when the correlation is greater than 30%. (d–f) PLS components of SSRD (black line) and de-trended wheat-yield time series (bars) for the two regions as indicated in Figure 1, R1 and R2 refer to the correlation coefficients between the time series for regions 1 and 2. [Colour figure can be viewed at wileyonlinelibrary.com].

applying the Mann–Kendall Z-test (Kendall, 1938) corrected for the effect of serial correlation (Yue and Wang, 2004). According to these parameters, wheat yield in both regions presented a normal distribution and a significant increasing trend probably due to socio-economic aspects and improved agricultural techniques (Lobell *et al.*, 2011; Lobell and Tebaldi, 2014), which could compensate for the possible negative effects of future climatic change (Ewert

et al., 2006; Long *et al.*, 2006; Lobell and Field, 2007; Tubiello and Fischer, 2007; Eitzinger *et al.*, 2009; Falloon and Betts, 2010; Finger, 2010; Trnka *et al.*, 2011, 2015; Asseng *et al.*, 2015).

Figure 1(b) shows the time series of the wheat yield of each region in bars before de-trending. These denote an increasing trend and high (low) productivity for the years 1988, 1996, 2004, 2007 and 2013 (1981, 1983, 1995, 2005

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

S. HERNÁNDEZ-BARRERA AND C. RODRÍGUEZ-PUEBLA

Table 3. Metrics of the linear model between wheat yield and PLS components of solar radiation.

	R^2	R^2_{CV}	RMSE	DW	a	b	c
Region 1	0.813	0.795	0.153	2.2	-0.129 ± 0.040	-0.129 ± 0.032	-0.103 ± 0.041
Region 2	0.877	0.859	0.165	2.0	-0.123 ± 0.043	-0.247 ± 0.034	-0.118 ± 0.044

DW, Durbin–Watson test. R -squared before (R^2) and after (R^2_{CV}) cross-validation. Linear equation parameters (a , b , c) for regions 1 and 2.

and 2012), which were relatively wet (dry) years in Spain (Vicente-Serrano *et al.*, 2014).

3.2. Effect of large-scale variables

Defining the statistical model considers the response or regression analysis of wheat yield to the potential predictors. The potential predictors (X) are the variables MSL, Z500, U250, SSRD and SST in different seasons and the dependent variables (Y) are the two wheat-yield time series corresponding to each region. PLS regression individually applied to each field (X) by retaining one component according to test considerations. The X and Y data were normalized by subtracting the mean and dividing by the standard deviation. The quality of the modelling relationships was evaluated by computing the metrics depicted in Table 2, which are the variance in X ($\text{Var}X$) and Y ($\text{Var}Y$), the R -squared before (R^2) and after (R^2_{CV}) applying cross-validation, and the RMSE of the residuals. We provide results only for the fields and seasons that showed significant association after cross-validation when p -value < 0.05 . The seasons considered were autumn (SON) of the previous year, winter (DJF), and spring (MAM) of the same year the yield was harvested. From the results depicted in Table 2, we determined that SSRD variability accounts for greater variance in the historical wheat-yield data, namely 62%, 65% and 63% in SON, DJF and MAM, respectively. Hence, we can infer that better models can be obtained using SSRD data to characterize the behaviour of wheat-yield variability.

Figure 2 shows the spatial modes of the SSRD by regressing the SSRD data on the standardized PLS components, producing a positive centre-of-action over the Iberian Peninsula. The corresponding temporal PLS components are represented in conjunction with the wheat-yield time series (in bars). It is worth noting the negative effect of PLS radiation components on wheat yield.

3.3. Empirical model

The model to estimate wheat-yield was obtained from the potential predictors identified in the previous section by applying stepwise linear regression (Wilks, 2006). This approach added or removed variables at each step taking into account the criterion of minimizing the square error. The optimal combination of predictors selected the PLS components of SSRD in the three seasons (i.e. autumn, winter and spring). Hence, the empirical model is described in the following way:

$$Y = a \cdot \text{PLS_SSRD}_{\text{SON}} + b \cdot \text{PLS_SSRD}_{\text{DJF}} + c \cdot \text{PLS_SSRD}_{\text{MAM}}$$

where Y corresponds with wheat yield in each region; $\text{PLS_SSRD}_{\text{SON}}$, $\text{PLS_SSRD}_{\text{DJF}}$ and $\text{PLS_SSRD}_{\text{MAM}}$ are the PLS components or the time series associated with the modes of SSRD in autumn, winter and spring, respectively. That is, the statistical procedure did not include other large-scale variables in the model because atmospheric circulation and SSTs respond to radiative changes and hence they covariate with SSRD. For instance, PLS_SSRD in spring is correlated with PLS_Z500 (-0.70 ± 0.09), PLS_U250 (-0.73 ± 0.08) and PLS_SST over the Pacific (0.52 ± 0.11); PLS_SSRD in winter is correlated with PLS_SST over the North Atlantic area (-0.57 ± 0.10). The correlation coefficients and confidence interval at 95% were obtained by the bootstrap procedure (Wilks, 2006).

Cross-validation was applied to test how well a model estimates the predictions. Leave-one-out cross-validation consisted of building a regression model, removing 1 year, and using this model to predict wheat yield of the omitted year. This procedure was repeated for all years. Then, the predicted values were used to obtain the metrics depicted in Table 3 and evaluate the model predictions. The predicted R -squared value derived for the fitted model before (R^2) and after (R^2_{CV}) cross-validation are similar (i.e. 0.81 and 0.80 in the case of region 1 and 0.88 and 0.86 in the case of region 2). Therefore, the proposed models are robust and there is probably no over-fitting. Table 3 also depicts the RMSE of the predicted residual and the Durbin–Watson (DW) to test spread and independence, respectively (when $\text{DW} > 1.3$). The parameters of the regression coefficients (a , b and c) indicate the relative contribution of SSRD in each season to the vegetative cycle of wheat yield; these parameters were estimated with the standard errors. We point out the greater relevance of SSRD for winter over region 2.

To gain a better understanding of the seasonal effects of SSRD on wheat yield, a composite map of the difference in the de-trended SSRD for 5 years of high and low wheat yield are represented in Figure 3. This suggests significant negative SSRD differences over Spain (dotted areas, T -test > 2.5) lead to greater positive wheat-yield changes. This observational relationship can be interpreted because higher solar radiation increases transpiration demand, thus enhancing water stress and lowering yields (Ramirez-Villegas *et al.*, 2015). In addition, more solar radiation implies less cloudiness, less precipitation, lower minimum temperatures and higher maximum temperatures.

Figure 4(a) and (b) compare observed and predicted wheat yields in regions 1 and 2, with a 95% confidence interval for the predictions, represented by the error

WHEAT YIELD AND SOLAR RADIATION

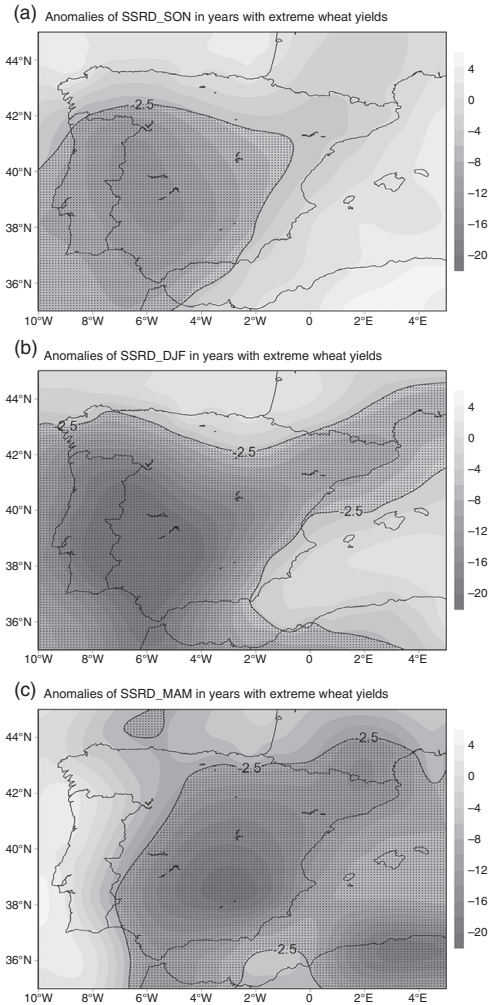


Figure 3. Anomalies of de-trended SSRD (W m^{-2}) between the 5 years of high and low wheat yield for the period of 1980–2014. Dotted regions correspond to significance at the 95% confidence level for the difference in SSRD.

bars. These figures show some regional differences in amplitude.

The metrics depicted in Table 3 support the robustness of the proposed models for describing wheat-yield variability in regions 1 and 2, indicating their possible use to investigate the impact of climate change. In the discussion section, we compare performances of the model based on SSRD and the proposed in HB2016.

3.4. Application to project wheat yield from CMIP5 models

Having shown that the method works well, we next ask about the future trends of wheat yield. We address this

question using the patterns of the PLS regression from the observational period with the variables SSRD in SON, DJF and MAM of each CMIP5 model to derive simulated PLS components. The bootstrap evaluation method indicated that the spread of the variance accounted for by the PLS regression modes is small (not shown) and the pattern structures of the observed and GCM model are quite similar and stable. The PLS and linear regression approaches combined the relevant information to estimate the wheat yield under different climate conditions; however, it used the parameters obtained in the calibration period. Figures S3(a) and (b) in Appendix S1 show the projections in the two regions with the spread of all simulations. Nevertheless, to reduce the effect of the choice of GCMs simulation we computed the multi-model ensemble by averaging the wheat-yield simulations (Martre *et al.*, 2015). The ensemble mean of wheat yield was determined with one realization of each model to give all models the same weight. These empirical models are not suitable for predicting yields 1 year or several years ahead but can be useful for predicting yield trends under other climate conditions in a specific region. Therefore, we focused on the yield trends of the individual models and the multi-model, which was isolated through the EEMD approach from each model. Figure 5 shows the trend time series of the different wheat-yield simulations, including the ensemble mean. Most of the models displayed a tendency toward wheat-yield reduction; this trend was more pronounced in the case of the multi-model. However, comparison of the trend results from historical and RCP8.5 experiments revealed differences, even showing an increase for some periods. Thus, Figure 6 presents the trends throughout the 20th and 21st centuries, quantifying variations (T ha^{-1} in 100 years) through Sen’s estimator and gauging their significance with the Mann–Kendall Z test (when Z tests higher than $|2|$). For the 20th century, the model CMCC-CESM displayed a trend toward significant wheat-yield increase as in our previous study (HB2016); here, the model HadGEM2-CC also exhibited an increasing trend in both regions. For the 21st century, all models exhibited a wheat-yield decreasing trend, with exception of the CMCC-CESM model. The multi-model indicates relative reduction with respect to mean wheat yield of about 6% and 8% in regions 1 and 2, respectively, which is lower than the decrease reported in HB2016 (32%).

Another way of obtaining change in wheat yield under warming conditions is comparing the distribution of the simulated wheat yield in different periods using a box-whisker representation: observation period (1980–2014) and future projection period (2070–2099). Figure 7 shows the results for the individual models and the multi-model ensemble. All models exhibited a reduction in the median, with exception of the CMCC-CESM model, which is in agreement with the previous result on trend variation. One issue that merits further explanation is the change in variability, which is beyond the objectives of this study.

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

S. HERNÁNDEZ-BARRERA AND C. RODRÍGUEZ-PUEBLA

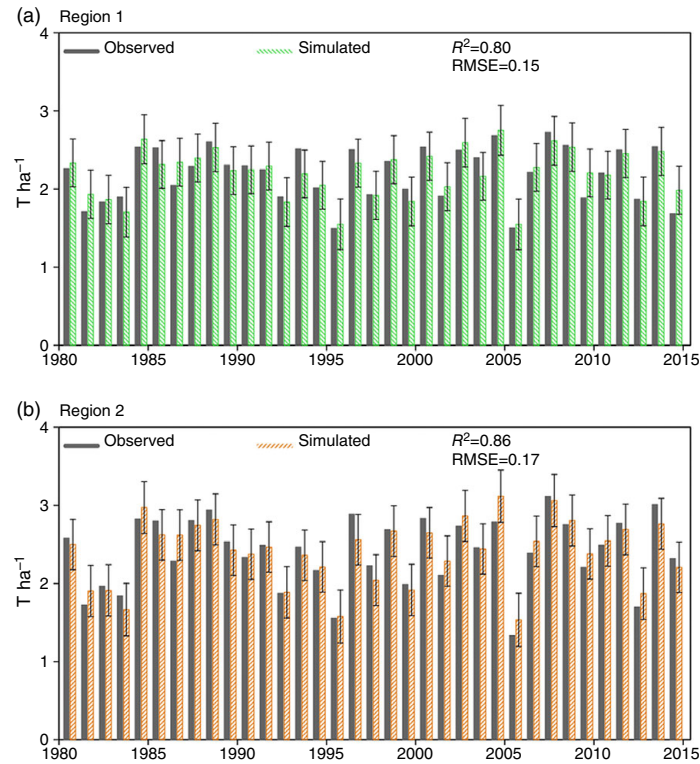


Figure 4. Time series of observed wheat yield (solid bar) and results of empirical model in diagonal downward pattern and diagonal upward pattern for region 1 (a) and region 2 (b) respectively. The model confidence interval is given by the error bar; R^2 gives the variance accounted for by the model. RMSE is the root mean square of the residual. [Colour figure can be viewed at wileyonlinelibrary.com].

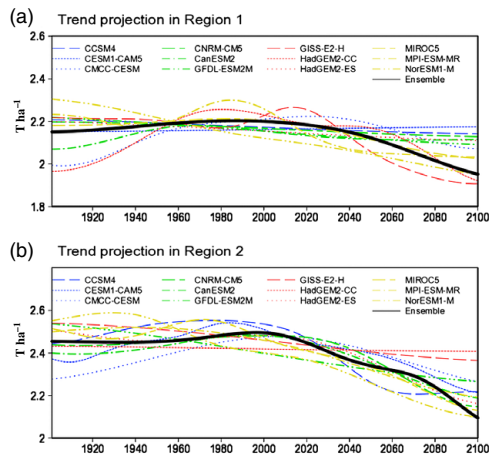


Figure 5. Trend time series filtered out from the simulated wheat yield of individual models and the ensemble multi-model in region 1 (a) and region 2 (b). [Colour figure can be viewed at wileyonlinelibrary.com].

4. Discussion and conclusions

This study has examined the role of solar radiation to describe wheat-yield variability in Spain, obtaining different solar radiation contributions according to the seasons. Ceglar *et al.* (2016) found that winter wheat yields in France are influenced by rainfall and temperature, but toward the southern part of France the role of solar radiation is important.

We used PLS regression to capture the modes of SSRD that drive wheat-yield variability. The PLS approach was used in the earlier study (HB2016) to extract the modes of SPI and DTR. The PLS regression was also applied by Ceglar *et al.* (2016) and Leng *et al.* (2016) with the aim of selecting variables associated with crops and excluding co-variability among predictors. However, we used PLS regression not only for dimension reduction, as in EOF analysis applied in earlier studies (Cantelaube *et al.*, 2004; Rodríguez-Puebla *et al.*, 2007) but also to provide co-variability between wheat yield and SSRD. Thus, making the PLS approach better at identifying the response of wheat yield to solar radiation.

It should be noted that the SSRD model introduces the effects of teleconnections on wheat yield, as indicated by

WHEAT YIELD AND SOLAR RADIATION

(a) Region 1		Sen		Z Kendall	
CCSM4		0.07	-0.05	0.79	-0.66
CESM1-CAM5	0.13	-0.18	2.20	-3.42	
CMCC-CESM	0.16	0.04	2.70	0.59	
CNRM-CM5	0.05	-0.21	0.74	-3.46	
CanESM2	0.09	-0.25	0.68	-3.44	
GFDL-ESM2M	0.01	-0.07	0.01	-1.24	
GISS-E2-H	0.13	-0.05	1.92	-0.44	
HadGEM2-CC	0.26	-0.17	3.91	-2.48	
HadGEM2-ES	0.07	-0.17	0.88	-3.18	
MIROC5	0.07	-0.09	2.45	-1.28	
MPI-ESM-MR	0.06	-0.13	1.03	-1.89	
NorESM1-M	-0.12	-0.11	-17.66	-1.73	
ENSEM	0.09	-0.12	4.13	-4.44	
		20	21	20	21

(b) Region 2		Sen		Z Kendall	
CCSM4		0.08	-0.12	0.55	-1.25
CESM1-CAM5	0.17	-0.36	2.21	-4.21	
CMCC-CESM	0.20	0.03	1.76	0.25	
CNRM-CM5	-0.01	-0.36	0.00	-3.48	
CanESM2	0.11	-0.41	0.77	-3.90	
GFDL-ESM2M	-0.05	-0.16	-0.57	-2.39	
GISS-E2-H	0.20	-0.02	1.86	0.04	
HadGEM2-CC	0.36	-0.27	3.15	-2.91	
HadGEM2-ES	0.04	-0.29	0.44	-4.36	
MIROC5	0.02	-0.15	0.33	-1.12	
MPI-ESM-MR	0.06	-0.11	0.76	-1.15	
NorESM1-M	-0.18	-0.28	-5.80	-3.00	
ENSEM	0.09	-0.19	2.69	-7.03	
		20	21	20	21

Figure 6. Wheat-yield changes in the 20th and 21st centuries assessed using Sen's estimator and significance of the trend as determined using the Mann-Kendall Z test for individual models and the ensemble multi-model. Negative and positive trends are highlighted in diagonal downward and upward pattern, respectively: region 1 (a); region 2 (b). [Colour figure can be viewed at wileyonlinelibrary.com].

the correlation coefficients between the PLS components of SSRD and teleconnection indices. The PLS component of SSRD in DJF is associated with the NAO (0.54 ± 0.10) and the East Atlantic (EA) (-0.43 ± 0.16) teleconnection indices (Barnston and Livezey, 1987). The influence of the NAO on wheat yield has been already denoted by Cantelaube *et al.* (2004) and Rodriguez-Puebla *et al.* (2007); the PLS component of SSRD in MAM is significantly correlated with the SCAND (-0.48 ± 0.15) index, which agrees with results obtained by Cantelaube *et al.* (2004) regarding wheat production in southern Europe and the SCAND

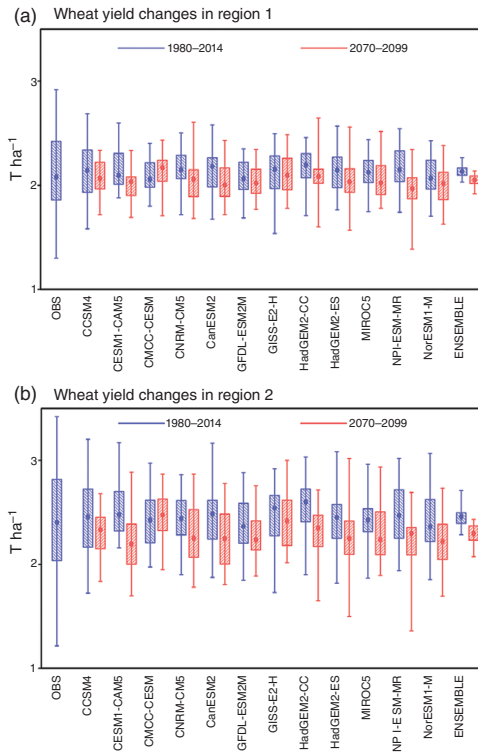


Figure 7. Box-whisker plot of distribution of wheat yield for observation, individual models, and the ensemble multi-model. Diagonal downward filled bars correspond to observational period (1980–2014); Diagonal upward filled bars correspond to projection for 2070–2090: region 1 (a); region 2 (b). [Colour figure can be viewed at wileyonlinelibrary.com].

pattern. The PLS component of SSRD in SON shows signals of the AMO (-0.24 ± 0.18). The AMO (Enfield *et al.*, 2001) is a variability mode in the entire North Atlantic defined by its SST anomalies and has significant impacts on the European summer climate (Sutton and Hodson, 2007). Therefore, our results contribute to the knowledge of how teleconnections influence wheat yield.

The climate-yield relationships vary geographically (Trnka *et al.*, 2016). In the case of Spain, the Figure S4 in Appendix S1 shows the effects of climate variables in the vegetative cycle of wheat by representing composite maps of basic climate variables, such as maximum temperature (TX), minimum temperature (TN), SSRD and derived variables such as SPI and DTR, for the three seasons autumn (SON), winter (DJF) and spring (MAM). The panels of Figure S4 in Appendix S1 indicate a wheat yield increase under higher values of SPI, lower values of SSRD and lower values of DTR along the vegetative cycle. In Spain, soil moisture is one of the most important factors affecting wheat mainly during sowing (autumn) and maturity phases (spring). Trnka *et al.* (2015) indicated the important effects of drought stress on soils with a lower water-holding capacity. Soil moisture depends on rainfall

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

S. HERNÁNDEZ-BARRERA AND C. RODRÍGUEZ-PUEBLA

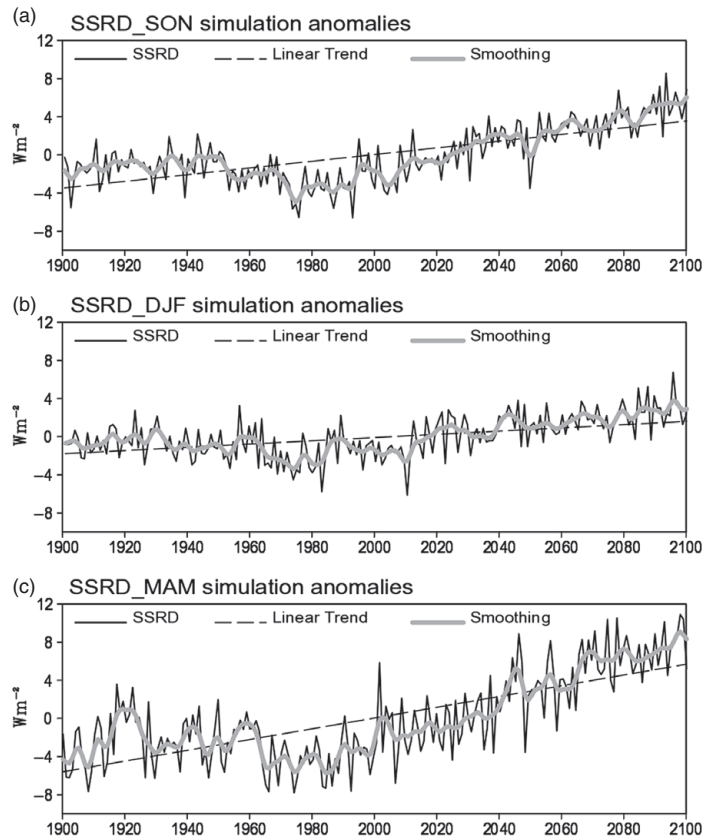


Figure 8. Multi-model simulation anomalies of the spatially averaged time series across Spain of the SSRD in Wm^{-2} : (a) in SON, (b) in DJF, and (c) in MAM. The black line represents the simulation, the thick grey line represents the 15-year smoothing, and the dashed line indicates the linear trend.

and evapotranspiration. Recently, Páscoa *et al.* (2016) investigated the effect of drought on wheat yield in the Iberian Peninsula. We note that soil moisture conditions may also depend on solar radiation (Leng *et al.*, 2016). For example, the correlation coefficients between the PLS_SSRD and PLS components of the standardized precipitation index are significantly correlated in autumn (-0.40 ± 0.13) and in spring (-0.80 ± 0.07). In winter, low minimum temperature and high diurnal temperature range affected negatively wheat yield while in spring increases when TX is lower. Further, the PLS_SSRD is correlated with the PLS component of diurnal temperature range in winter (0.57 ± 0.11). Figure S5 in Appendix S1 shows the regression patterns between SSRD and SPI, DTR, TX and TN to evidence that solar radiation is negatively associated with precipitation and minimum temperature and positively associated with diurnal temperature range and maximum temperature. These relationships are supported by a comparison of the statistical metrics of the models, depicted in the Table S2 in Appendix S1, which indicates the relative influence of variables on wheat yield along the

vegetative cycle. This reveals greater influence of solar radiation variability in autumn and winter with respect to the variables included in the model based on SPI and DTR; however, in spring, the effects of SSRD and SPI are more similar. Figure S6 in Appendix S1 compares both models in the two regions by means of scattergram representation, with better goodness-of-fit for the model based on SSRD. A local models' comparison is shown with the correlation patterns between the observed wheat yield in each province and estimated using SSRD model, and the estimated with the HB2016 model (Figure S7 in Appendix S1), showing greater field significance for the model based on SSRD (i.e. 71% of the points are significant against 65% for the model proposed in HB2016). The field significance is measured by the False Discovery Rate (FDR) procedure (Wilks, 2016). All these results point out improvements of the model based on SSRD with respect to the model that considers SPI and DTR.

We highlight the importance of SSRD to obtain models for wheat-yield projections because it could reduce uncertainty with respect to the projections based on the

regional variables SPI and DTR. On one hand, the results for wheat-yield trends are consistent with our previous work (HB2016), suggesting the risk of decreased wheat yield under warming conditions (Figure 6). However, the diversity of trend values of each model could be due to the contribution of internal variability (Deser *et al.*, 2014), which cause uncertainty in trend detection. In this study, we obtained the contribution of the forced variability to the spread of unforced variability by computing the signal-to-noise ratio (SNR) (Gonzalez-Reviriego *et al.*, 2015). The forced trend was determined by averaging the trend of all individual models. Then, we subtracted the forced trend from the trend time series of each model to obtain an approximation of the unforced trend caused by internal and structural model variability. The spread of the unforced trend across individual models was measured by the standard deviation. The division between the forced trend and the spread of the unforced trend could be a measure of SNR. In case of the 21st century, the SNR are -1.47 in region 1 and -1.42 in region 2. These values of SNR are greater than those obtained using the model based on SPI and DTR, which are -0.95 and -1.22 for regions 1 and 2, respectively. Therefore, the forced trend due to climate change is less uncertain in the case of the model based on SSRD because the SNR has a higher absolute value.

Wheat-yield projections can be used for planning and adaptation measurements. However, the effects of climate change on crops depend on the characteristics of climate change within a region and the different responses of wheat yield to climate (Licker *et al.*, 2013). In fact, Michel and Makowski (2013) found wheat yields to be stagnating and declining in some European countries but increasing in others. Nevertheless, a number of studies have found that climate change has a negative effect on potential wheat yield, considering projections of the variables that influence wheat production, for example, precipitation or temperature (Bell and Fischer, 1994; Pathak *et al.*, 2003; Luo *et al.*, 2005; Li *et al.*, 2010; Liu *et al.*, 2010, 2016; Lobell *et al.*, 2011; Chen *et al.*, 2013b). According to our results, the increase of solar radiation over Spain could force a wheat-yield decrease. Figure 8 shows the projected changes of SSRD in SON, DJF and MAM in the case of the multi-model. Note that the trend of SSRD to increase agrees with the brightening in Spain reported by Sanchez-Lorenzo *et al.* (2013) and Wild (2016). However, Chen *et al.* (2013a) found that in other areas, decreasing solar radiation had a negative impact on potential wheat yield using process crop modelling. Discrepancies between the effects of solar radiation on wheat yield may be due to regional differences on climate-yield relationships (Trnka *et al.*, 2016), however, this subject requires further investigation.

Acknowledgements

The authors thank to the referees for their insightful review on the manuscript. We also acknowledge the data providers: Spanish Agriculture, Food and Environment

(MAGRAMA) for crop data; ECMWF for ERA-interim reanalysis; E-OBS dataset from the EU-FP6 project ENSEMBLES; the U.S. Department of Energy's Program for Climate Model Diagnosis and Intercomparison provided CMIP5 data; the NOAA Earth System Research Laboratory (ESRL) (<http://www.esrl.noaa.gov/psd/data/climateindices/list/>) for the teleconnection indices. Thanks also to the developers of GrADS, CDO, NCL, MATLAB and R software.

This work was supported by the Ministry of Economy and Competitiveness of Spain under National project (CGL-2011-23209/CLI) and fellowship BES-2012-054447 granted to S. Hernandez-Barrera.

References

- Asseng S, Ewert F, Rosenzweig C, Jones JW, Hatfield JL, Ruane AC, Boote KJ, Thorburn PJ, Rötter RP, Cammarano D, Brisson N, Basso B, Martre P, Aggarwal PK, Angulo C, Bertuzzi P, Biernath C, Challinor AJ, Doltra J, Gayler S, Goldberg R, Grant R, Heng L, Hooker J, Hunt LA, Ingwersen J, Izauralde RC, Kersebaum KC, Müller C, Naresh Kumar S, Nendel C, O'Leary G, Olesen JE, Osborne TM, Palosuo T, Priesack E, Ripoche D, Semenov MA, Shcherbak I, Steduto P, Stöckle C, Stratonovitch P, Streck T, Supit I, Tao F, Travasso M, Waha K, Wallach D, White JW, Williams JR, Wolf J. 2013. Uncertainty in simulating wheat yields under climate change. *Nat. Clim. Change* **3**(9): 827–832, doi: 10.1038/nclimate1916.
- Asseng S, Ewert F, Martre P, Rötter RP, Lobell DB, Cammarano D, Kimball BA, Ottman MJ, Wall GW, White JW, Reynolds MP, Alderman PD, Prasad PVV, Aggarwal PK, Anothai J, Basso B, Biernath C, Challinor AJ, de Sanctis G, Doltra J, Fereres E, Garcia-Vila M, Gayler S, Hoogenboom G, Hunt LA, Izauralde RC, Jabloun M, Jones CD, Kersebaum KC, Koehler AK, Müller C, Naresh Kumar S, Nendel C, O'Leary G, Olesen JE, Palosuo T, Priesack E, Eyshi Rezaei E, Ruane AC, Semenov MA, Shcherbak I, Stöckle C, Stratonovitch P, Streck T, Supit I, Tao F, Thorburn PJ, Waha K, Wang E, Wallach D, Wolf J, Zhao Z, Zhu Y. 2015. Rising temperatures reduce global wheat production. *Nat. Clim. Change* **5**(2): 143–147, doi: 10.1038/NCLIMATE2470.
- Atkinson MD, Kettlewell PS, Hollins PD, Stephenson DB, Hardwick NV. 2005. Summer climate mediates UK wheat quality response to winter North Atlantic Oscillation. *Agric. For. Meteorol.* **130**(1–2): 27–37, doi: 10.1016/j.agrformet.2005.02.002.
- Baker NC, Taylor PC. 2016. A framework for evaluating climate model performance metrics. *J. Clim.* **29**(5): 1773–1782, doi: 10.1175/jcli-d-15-0114.1.
- Barnston AG, Livezey RE. 1987. Classification, seasonality and persistence of low-frequency atmospheric circulation patterns. *Mon. Weather Rev.* **115**(6): 1083–1126.
- Bell MA, Fischer RA. 1994. Using yield prediction models to assess yield gains – a case-study for wheat. *Field Crop Res.* **36**(2): 161–166.
- Cantelaube P, Terres JM, Doblas-Reyes FJ. 2004. Influence of climate variability on European agriculture – analysis of winter wheat production. *Clim. Res.* **27**(2): 135–144.
- Capa-Morocho M, Rodriguez-Fonseca B, Ruiz-Ramos M. 2016. El Niño influence on potential maize yield in Iberian Peninsula. *Int. J. Climatol.* **36**(3): 1313–1330, doi: 10.1002/joc.4426.
- Ceglar A, Toret A, Lecerf R, Van der Velde M, Dentener F. 2016. Impact of meteorological drivers on regional inter-annual crop yield variability in France. *Agric. For. Meteorol.* **216**: 58–67, doi: 10.1016/j.agrformet.2015.10.004.
- Challinor AJ, Watson J, Lobell DB, Howden SM, Smith DR, Chhetri N. 2014. A meta-analysis of crop yield under climate change and adaptation. *Nat. Clim. Change* **4**(4): 287–291, doi: 10.1038/nclimate2153.
- Chen C, Baethgen WE, Robertson A. 2013a. Contributions of individual variation in temperature, solar radiation and precipitation to crop yield in the North China Plain, 1961–2003. *Clim. Change* **116**(3–4): 767–788, doi: 10.1007/s10584-012-0509-2.
- Chen C, Greene AM, Robertson AW, Baethgen WE, Eamus D. 2013b. Scenario development for estimating potential climate change impacts on crop production in the North China Plain. *Int. J. Climatol.* **33**(15): 3124–3140, doi: 10.1002/joc.3648.

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

S. HERNÁNDEZ-BARRERA AND C. RODRÍGUEZ-PUEBLA

- Chen X, Wang M, Zhang Y, Feng Y, Wu Z, Huang NE. 2013c. Detecting signals from data with noise: theory and applications. *J. Atmos. Sci.* **70**(5): 1489–1504, doi: 10.1175/jas-d-12-0213.1.
- Conradt T, Gornott C, Wechsung F. 2016. Extending and improving regionalized winter wheat and silage maize yield regression models for Germany: enhancing the predictive skill by panel definition through cluster analysis. *Agric. For. Meteorol.* **216**: 68–81, doi: 10.1016/j.agrformet.2015.10.003.
- Dalla Marta A, Grifoni D, Mancini M, Zipoli G, Orlandini S. 2011. The influence of climate on durum wheat quality in Tuscany, Central Italy. *Int. J. Biometeorol.* **55**(1): 87–96, doi: 10.1007/s00484-010-0310-8.
- Dee DP, Uppala SM, Simmons AJ, Berrisford P, Poli P, Kobayashi S, Andrae U, Balmaseda MA, Balsamo G, Bauer P, Bechtold P, Beljaars ACM, van de Berg L, Bidlot J, Bormann N, Delsol C, Dragani R, Fuentes M, Geer AJ, Haimberger L, Healy SB, Hersbach H, Holm EV, Isaksen I, Kallberg P, Kohler M, Matricardi M, McNally AP, Monge-Sanz BM, Morcrette JJ, Park BK, Peubey C, de Rosnay P, Tavolato C, Thepaut JN, Vitart F. 2011. The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Q. J. R. Meteorol. Soc.* **137**(656): 553–597, doi: 10.1002/qj.828.
- Deser C, Phillips AS, Alexander MA, Smoliak BV. 2014. Projecting North American Climate over the next 50 years: uncertainty due to internal variability. *J. Clim.* **27**(6): 2271–2296, doi: 10.1175/JCLI-D-13-00451.1.
- Eitzinger J, Kubu G, Alexandrov V, Utset A, Mihailovic DT, Lalic B, Trnka M, Zalud Z, Semerádova D, Ventrella D, Anastasiou DP, Medany M, Altaier S, Olejnik J, Lesny J, Nemessho N, Nikolaev M, Simota C, Cojocar G. 2009. Adaptation of vulnerable regional agricultural systems in Europe to climate change – results from the ADAGIO project. *Adv. Sci. Res.* **3**: 133–135.
- Enfield DB, Mestas-Nunez AM, Trimble PJ. 2001. The Atlantic Multidecadal Oscillation and its relation to rainfall and river flows in the continental US. *Geophys. Res. Lett.* **28**(10): 2077–2080, doi: 10.1029/2000gl012745.
- Ewert F, Rounsevell M, Reginster I, Metzger M, Leemans R. 2006. Technology development and climate change as drivers of future agricultural land use. In *Agriculture and climate beyond 2015*, Brouwer F, McCarl B (eds). Springer Academic Publishers: Dordrecht, The Netherlands, 33.
- Ewert F, Rötter RP, Bindi M, Webber Heidi, Trnka M, Kersebaum KC, Olesen JE, Ittersum MK van, Janssen SJC, Rivington M, Semenov MA, Wallach D, Porter JR, Stewart D, Verhagen J, Gaiser T, Palosuo T, Tao F, Nendel C, Roggero PP, Bartosová L, Asseng S. 2015. Crop modelling for integrated assessment of risk to food production from climate change. *Environ. Model Softw.* **72**: 287–303, doi: 10.1016/j.envsoft.2014.12.003.
- Falloon P, Betts R. 2010. Climate impacts on European agriculture and water management in the context of adaptation and mitigation – the importance of an integrated approach. *Sci. Total Environ.* **408**(23): 5667–5687, doi: 10.1016/j.scitotenv.2009.05.002.
- FAO. 2003. World agriculture: towards 2015/1030. In *A FAO Perspective*, Bruinsma J (ed). Food and Agricultural Organization of the United Nations: Rome, 432 pp.
- Finger R. 2010. Evidence of slowing yield growth – the example of Swiss cereal yields. *Food Policy* **35**(2): 175–182, doi: 10.1016/j.foodpol.2009.11.004.
- Gimeno L, Ribera P, Iglesias R, de la Torre L, Garcia R, Hernandez E. 2002. Identification of empirical relationships between indices of ENSO and NAO and agricultural yields in Spain. *Clim. Res.* **21**(2): 165–172, doi: 10.3354/cr021165.
- Gonsamo A, Chen JM. 2015. Winter teleconnections can predict the ensuing summer European crop productivity. *Proc. Natl. Acad. Sci. U.S.A.* **112**(18): E2265–E2266, doi: 10.1073/pnas.1503450112.
- Gonzalez-Reviriego N, Rodriguez-Puebla C, Rodriguez-Fonseca B. 2015. Evaluation of observed and simulated teleconnections over the Euro-Atlantic region on the basis of partial least squares regression. *Clim. Dyn.* **44**(11–12): 2989–3014, doi: 10.1007/s00382-014-2367-2.
- Gornott C, Wechsung F. 2016. Statistical regression models for assessing climate impacts on crop yields: a validation study for winter wheat and silage maize in Germany. *Agric. For. Meteorol.* **217**: 89–100, doi: 10.1016/j.agrformet.2015.10.005.
- Gouveia C, Trigo RM, DaCamara CC, Libonati R, Pereira JMC. 2008. The North Atlantic Oscillation and European vegetation dynamics. *Int. J. Climatol.* **28**(14): 1835–1847, doi: 10.1002/joc.1682.
- Hansen JW, Jones JW, Irmak A, Royce FS. 2001. ENSO impacts on crop production in the Southeast US. In *Impacts of El Niño and Climate Variability on Agriculture*. ASA Special Publication no. 63, Rosenzweig C, Boote KJ, Hollinger S, Iglesias A, Phillips J (eds). American Society of Agronomy: Madison, WI, 55–76.
- Hansen JW, Challinor A, Ines A, Wheeler T, Moron V. 2006. Translating climate forecasts into agricultural terms: advances and challenges. *Clim. Res.* **33**(1): 27–41, doi: 10.3354/cr033027.
- Hernandez-Barrera S, Rodríguez-Puebla C, Challinor A. 2016. Effects of diurnal temperature range and drought on wheat yield in Spain. *Theor. Appl. Climatol.*, doi: 10.1007/s00704-016-1779-9.
- Huang NE, Shen Z, Long SR, Wu MLC, Shih HH, Zheng QN, Yen NC, Tung CC, Liu HH. 1998. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proc. R. Soc. A Lon. Ser. Math. Phys. Eng. Sci.* **454**(1971): 903–995.
- Iglesias A, Rosenzweig C, Pereira D. 2000. Agricultural impacts of climate change in Spain: developing tools for a spatial analysis. *Glob. Environ. Change Hum. Policy Dimens.* **10**(1): 69–80.
- Iizumi T, Okada M, Yokozawa M. 2014a. A meteorological forcing data set for global crop modeling: development, evaluation, and intercomparison. *J. Geophys. Res.-Atmos.* **119**(2): 363–384, doi: 10.1002/2013JD020130.
- Iizumi T, Luo JJ, Challinor AJ, Sakurai G, Yokozawa M, Sakuma H, Brown ME, Yamagata T. 2014b. Impacts of El Niño Southern Oscillation on the global yields of major crops. *Nat. Commun.* **5**(7): 3712, doi: 10.1038/ncomms4712.
- IPCC. 2014. Chapter 7 Food Security and Food Production Systems. In *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and Sectoral Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, Field CB, Barros VR, Dokken DJ, Mach KJ, Mastrandrea MD, Bilir TE, Chatterjee M, Ebi KL, Estrada YO, Genova RC, Girma B, Kissel ES, Levy AN, MacCracken S, Mastrandrea PR, White LL (eds). Cambridge University Press: Cambridge, UK and New York, NY, 485–533.
- Jarlan L, Abaoui J, Duchemin B, Ouldabba A, Tourre YM, Khabba S, Le Page M, Balaghi R, Mokssit A, Chehbouni G. 2014. Linkages between common wheat yields and climate in Morocco (1982–2008). *Int. J. Biometeorol.* **58**(7): 1489–1502, doi: 10.1007/s00484-013-0753-9.
- Kendall M. 1938. A new measure of rank correlation. *Biometrika* **30**(1–2): 81–89.
- Knutti R, Sedlacek J. 2013. Robustness and uncertainties in the new CMIP5 climate model projections. *Nat. Clim. Change* **3**(4): 369–373, doi: 10.1038/nclimate1716.
- Knutti R, Allen MR, Friedlingstein P, Gregory JM, Hegerl Gabi, Meehl GA, Meinshausen M, Murphy JM, Plattner GK, Raper SCB, Stocker TF, Stott PA, Teng H, Wigley TML. 2008. A review of uncertainties in global temperature projections over the twenty-first century. *J. Clim.* **21**(11): 2651–2663, doi: 10.1175/2007jcli2119.1.
- Leng G, Zhang X, Huang M, Asrar GR, Leung R. 2016. The role of climate covariability on crop yields in the conterminous United States. *Sci. Rep.* **6**: 33160, doi: 10.1038/srep33160.
- Lesk C, Rowhani P, Ramankutty N. 2016. Influence of extreme weather disasters on global crop production. *Nature* **529**(7584): 84, doi: 10.1038/nclimate1716.
- Li SA, Wheeler T, Challinor A, Lin E, Ju H, Xu YL. 2010. The observed relationships between wheat and climate in China. *Agric. For. Meteorol.* **150**(11): 1412–1419, doi: 10.1016/j.agrformet.2010.07.003.
- Licker R, Kucharik CJ, Dore T, Lindeman MJ, Makowski D. 2013. Climatic impacts on winter wheat yields in Picardy, France and Rostov, Russia: 1973–2010. *Agric. For. Meteorol.* **176**: 25–37, doi: 10.1016/j.agrformet.2013.02.010.
- Liu SX, Mo XG, Lin ZH. 2010. Crop yield responses to climate change in the Huang-Huai-Hai Plain of China. *Agric. Water Manag.* **97**(8): 1195–1209, doi: 10.1016/j.agwat.2010.03.001.
- Liu B, Asseng S, Müller C, Ewert F, Elliott J, Lobell DB, Martre P, Ruane AC, Wallach D, Jones JW, Rosenzweig C, Aggarwal PK, Alderman PD, Anothai J, Basso B, Biernath C, Cammarano D, Challinor A, Deryng D, De Sanctis G, Doltra J, Fereres E, Folberth C, Garcia-Vila M, Gayler S, Hoogenboom G, Hunt LA, Izaurrealde RC, Jabloun M, Jones CD, Kersebaum KC, Kimball BA, Koehler AK, Kumar SN, Nendel C, O’Leary G, Olesen JE, Ottman MJ, Palosuo T, Prasad PVV, Priesack E, Pugh TAM, Reynolds M, Rezaei EE, Rötter RP, Schmid E, Semenov MA, Shcherbak I, Stehfest E, Stöckle CO, Stratonovitch P, Streck T, Supit I, Tao F, Thorburn P, Waha K, Wall GW, Wang E, White JW, Wolf J, Zhao Z, Zhu Y. 2016. Similar negative impacts of temperature on global wheat yield estimated by three independent methods. *Nat. Clim. Change* **6**(12): 1130–1136, doi: 10.1038/nclimate3115.
- Lobell DB. 2013. Errors in climate datasets and their effects on statistical crop models. *Agric. For. Meteorol.* **170**: 58–66, doi: 10.1016/j.agrformet.2012.05.013.

WHEAT YIELD AND SOLAR RADIATION

- Lobell DB, Burke MB. 2008. Why are agricultural impacts of climate change so uncertain? The importance of temperature relative to precipitation. *Environ. Res. Lett.* **3**(3): 034007, doi: 10.1088/1748-9326/3/3/034007.
- Lobell DB, Burke MB. 2010. On the use of statistical models to predict crop yield responses to climate change. *Agric. For. Meteorol.* **150**(11): 1443–1452, doi: 10.1016/j.agrformet.2010.07.008.
- Lobell DB, Field CB. 2007. Global scale climate – crop yield relationships and the impacts of recent warming. *Environ. Res. Lett.* **2**(1): 014002, doi: 10.1088/1748-9326/2/1/014002.
- Lobell DB, Tebaldi C. 2014. Getting caught with our plants down: the risks of a global crop yield slowdown from climate trends in the next two decades. *Environ. Res. Lett.* **9**(7): 074003, doi: 10.1088/1748-9326/9/7/074003.
- Lobell DB, Schlenker W, Costa-Roberts J. 2011. Climate trends and global crop production since 1980. *Science* **333**(6042): 616–620, doi: 10.1126/science.1204531.
- Long SP, Ainsworth EA, Leakey ADB, Nosberger J, Ort DR. 2006. Food for thought: lower-than-expected crop yield stimulation with rising CO₂ concentrations. *Science* **312**(5782): 1918–1921, doi: 10.1126/science.1114722.
- Luo QY, Bellotti W, Williams M, Bryan B. 2005. Potential impact of climate change on wheat yield in South Australia. *Agric. For. Meteorol.* **132**(3–4): 273–285.
- MAGRAMA. 2015. Anuario de Estadística 2015. Spanish agriculture, food and environment department. <http://www.magrama.gob.es/es/estadistica/temas/estadisticasagrarias/agricultura/avances-superficies-producciones-agricolas/> (accessed 1 December 2016).
- Martre P, Wallach D, Asseng S, Ewert F, Jones JW, Rötter RP, Boote KJ, Ruane AC, Thorburn PJ, Cammarano D, Hatfield JL, Rosenzweig C, Aggarwal PK, Angulo C, Basso B, Bertuzzi P, Biernath C, Brisson N, Challinor AJ, Doltra J, Gayler S, Goldberg R, Grant RF, Heng L, Hooker J, Hunt LA, Ingwersen J, Izaurralde RC, Kersebaum KC, Müller C, Kumar SN, Nendel C, O’leary G, Olesen JE, Osborne TM, Palosuo T, Priesack E, Ripoche D, Semenov MA, Shcherbak I, Steduto P, Stöckle CO, Stratonovitch P, Streck T, Supit I, Tao F, Travasso M, Waha K, White JW, Wolf J. 2015. Multimodel ensembles of wheat growth: many models are better than one. *Glob. Change Biol.* **21**(2): 911–925, doi: 10.1111/gcb.12768.
- Mearns LO. 2003. Issues in the impacts of climate variability and change on agriculture – applications to the southeastern United States. *Clim. Change* **60**(1–2): 1–6.
- Michel L, Makowski D. 2013. Comparison of statistical models for analyzing wheat yield time series. *PLoS One* **8**(10): e78615, doi: 10.1371/journal.pone.0078615.
- Moore FC, Lobell DB. 2014. Adaptation potential of European agriculture in response to climate change. *Nat. Clim. Change* **4**(7): 610–614, doi: 10.1038/nclimate2228.
- Moore FC, Lobell DB. 2015. The fingerprint of climate trends on European crop yields. *Proc. Natl. Acad. Sci. U.S.A.* **112**(9): 2670–2675, doi: 10.1073/pnas.1409606112.
- Moron V, Robertson AW, Qian JH. 2010. Local versus regional-scale characteristics of monsoon onset and post-onset rainfall over Indonesia. *Clim. Dyn.* **34**(2–3): 281–299, doi: 10.1007/s00382-009-0547-2.
- Nicholls N. 1997. Increased Australian wheat yield due to recent climate trends. *Nature* **387**(6632): 484–485.
- Orlandini S, Dalla Marta A, Mancini M, and Grifoni D. 2011. Impact of NAO on mediterranean crop production. In *Hydrological, Socio-economic and Ecological Impacts of the North Atlantic Oscillation in the Mediterranean Region, Advances in Global Change Research 46*, Vicente-Serrano S, Trigo RM (eds). Springer Netherlands, Springer Science+Business Media B.V., The Netherlands, 103–112, doi: 10.1007/978-94-007-1372-7_8.
- Páscoa P, Gouveia CM, Russo A, Trigo RM. 2016. The role of drought on wheat yield interannual variability in the Iberian Peninsula from 1929 to 2012. *Int. J. Biometeorol.* doi: 10.1007/s00484-016-1224-x.
- Pathak H, Ladha JK, Aggarwal PK, Peng S, Das S, Singh Y, Singh B, Kamra SK, Mishra B, Sastri A, Aggarwal HP, Das DK, Gupta RK. 2003. Trends of climatic potential and on-farm yields of rice and wheat in the Indo-Gangetic Plains. *Field Crop Res.* **80**(3): 223–234, doi: 10.1016/S0378-4290(02)00194-6.
- Podesta G, Letson D, Messina C, Royce F, Ferreyra RA, Jones J, Hansen J, Liouet I, Grondona M, O’Brien JJ. 2002. Use of ENSO-related climate information in agricultural decision making in Argentina: a pilot experience. *Agric. Syst.* **74**(3): 371–392, doi: 10.1016/S0308-521X(02)00046-X.
- Ramirez-Villegas J, Challinor A. 2012. Assessing relevant climate data for agricultural applications. *Agric. For. Meteorol.* **161**: 26–45, doi: 10.1016/j.agrformet.2012.03.015.
- Ramirez-Villegas J, Koehler AK, Challinor AJ. 2015. Assessing uncertainty and complexity in regional-scale crop model simulations. *Eur. J. Agron.* doi: 10.1016/j.eja.2015.11.021.
- Rodríguez-Puebla C, Ayuso SM, Frias MD, García-Casado LA. 2007. Effects of climate variation on winter cereal production in Spain. *Clim. Res.* **34**(3): 223–232.
- Rosipal R, Kramer N. 2006. Overview and recent advances in partial least squares. *Subspace Lat. Struct. Feat. Select.* **3940**: 34–51.
- Rousseeuw PJ. 1987. Silhouettes – a graphical aid to the interpretation and validation of cluster-analysis. *J. Comput. Appl. Math.* **20**: 53–65, doi: 10.1016/0377-0427(87)90125-7.
- Royce FS, Fraisse CW, Baigorria GA. 2011. ENSO classification indices and summer crop yields in the Southeastern USA. *Agric. For. Meteorol.* **151**(7): 817–826, doi: 10.1016/j.agrformet.2011.01.017.
- Sanchez-Lorenzo A, Calbo J, Wild M. 2013. Global and diffuse solar radiation in Spain: building a homogeneous dataset and assessing their trends. *Glob. Planet. Change* **100**: 343–352, doi: 10.1016/j.gloplacha.2012.11.010.
- Schulzweida U. 2015. CDO Climate Data Operators, User’s guide. Max-Planck-Institut für Meteorologie, Hamburg, Germany. <https://code.zmaw.de/projects/cdo>.
- Sen PK. 1968. Estimates of regression coefficient based on kendalls Tau. *J. Am. Stat. Assoc.* **63**(324): 1379–1389.
- Smith TM, Reynolds RW, Peterson TC, Lawrimore J. 2008. Improvements to NOAA’s historical merged land-ocean surface temperature analysis (1880–2006). *J. Clim.* **21**(10): 2283–2296, doi: 10.1175/2007jcli2100.1.
- Stenseth NC, Ottersen G, Hurrell JW, Mysterud A, Lima M, Chan KS, Yoccoz NG, Adlandsvik B. 2003. Studying climate effects on ecology through the use of climate indices: the North Atlantic Oscillation, El Niño Southern Oscillation and beyond. *Proc. Biol. Sci.* **270**(1529): 2087–2096, doi: 10.1098/rspb.2003.2415.
- Sutton RT, Hodson DLR. 2007. Climate response to basin-scale warming and cooling of the North Atlantic Ocean. *J. Clim.* **20**(5): 891–907, doi: 10.1175/JCLI4038.1.
- Taylor KE, Stouffer RJ, Meehl GA. 2012. An overview of CMIP5 and the experiment design. *Bull. Am. Meteorol. Soc.* **93**(4): 485–498, doi: 10.1175/bams-d-11-00094.1.
- Trnka M, Eitzinger J, Kapler P, Dubrovský M, Semerádová D, Žalud Z, Formayer H. 2007. Effect of estimated daily global solar radiation data on the results of crop growth models. *Sensors* **7**(10): 2330–2362.
- Trnka M, Olesen JE, Kersebaum KC, Skjelvag AO, Eitzinger J, Seguin B, Peltonen-Sainio P, Rotter R, Iglesias A, Orlandini S, Dubrovský M, Hlavinka P, Balek J, Eckersten H, Cloppet E, Calanca P, Gobin A, Vučeti V, Nejedlik P, Kumar S, Lalic B, Mestre A, Rossi F, Kozyra J, Alexandrov V, Semerádová D, Zalud Z. 2011. Agroclimatic conditions in Europe under climate change. *Glob. Change Biol.* **17**(7): 2298–2318, doi: 10.1111/j.1365-2486.2011.02396.x.
- Trnka M, Hlavinka P, Semenov MA. 2015. Adaptation option for wheat in Europe will be limited by increased adverse weather events under climate change. *J. R. Soc. Interface* **12**: 20150721, doi: 10.1098/rsif.2015.0721.
- Trnka M, Olesen JE, Kersebaum KC, Rötter RP, Brázdil R, Eitzinger J, Jansen S, Skjelvåg AO, Peltonen-Sainio P, Hlavinka P, Balek J, Eckersten H, Gobin A, Vučeti V, Dalla Marta A, Orlandini S, Alexandrov V, Semerádová D, Štěpánek P, Svobodová E, Rajdl K. 2016. Changing regional weather-crop yield relationships across Europe between 1901 and 2012. *Clim. Res.* **70**: 195–214, doi: 10.3354/cr01426.
- Tubiello FN, Fischer G. 2007. Reducing climate change impacts on agriculture: Global and regional effects of mitigation, 2000–2080. *Technol. Forecast. Soc. Change* **74**(7): 1030–1056.
- Vicente-Serrano SM, López-Moreno JI, Beguería S, Lorenzo-Lacruz J, Sánchez-Lorenzo A, García-Ruiz JM, Azorin-Molina C, Revuelto J, Trigo R, Coelho F, Espejo F. 2014. Evidence of increasing drought severity caused by temperature rise in southern Europe. *Environ. Res. Lett.* **9**(4), doi: 10.1088/1748-9326/9/4/044001.
- Watson J, Challinor AJ, Fricker TE, Ferro CAT. 2015. Comparing the effects of calibration and climate errors on a statistical crop model and a process-based crop model. *Clim. Change* **132**(1): 93–109, doi: 10.1007/s10584-014-1264-3.
- Wilby RL, Wigley TML, Conway D, Jones PD, Hewitson BC, Main J, Wilks DS. 1998. Statistical downscaling of general circulation model output: a comparison of methods. *Water Resour. Res.* **34**(11): 2995–3008, doi: 10.1029/98WR02577.

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

S. HERNÁNDEZ-BARRERA AND C. RODRÍGUEZ-PUEBLA

- Wild M. 2016. Decadal changes in radiative fluxes at land and ocean surfaces and their relevance for global warming. *WIREs Clim. Change* **7**(1): 91–107, doi: 10.1002/wcc.372.
- Wilks DS. 2006. *Statistical Methods in the Atmospheric Sciences*. International Geophysics Series, Vol. **91**, 2nd edn. Academic Press: San Diego, CA, 627 pp.
- Wilks DS. 2016. The stippling shows statistically significant gridpoints: how research results are routinely overstated and over-interpreted, and what to do about it. *Bull. Am. Meteorol. Soc.*, doi: 10.1175/BAMS-D-15-00267.1.
- Wold S, Høy M, Martens H, Trygg J, Westad F, MacGregor J, Wise BM. 2009. The PLS model space revisited. *J. Chemom.* **23**(1–2): 67–68, doi: 10.1002/cem.1171.
- Wu ZH, Huang NE, Wallace JM, Smoliak BV, Chen XY. 2011. On the time-varying trend in global-mean surface temperature. *Clim. Dyn.* **37**(3–4): 759–773, doi: 10.1007/s00382-011-1128-8.
- Yang RC, Stanton D, Blade SF, Helm J, Spaner D, Wright S, Domitruk D. 2006. Isoyield analysis of barley cultivar trials in the Canadian prairies. *J. Agron. Crop Sci.* **192**(4): 284–294, doi: 10.1111/j.1439-037X.2006.00209.x.
- Yue S, Wang CY. 2004. The Mann-Kendall test modified by effective sample size to detect trend in serially correlated hydrological series. *Water Resour. Manag.* **18**(3): 201–218, doi: 10.1023/b:warm.0000043140.61082.60.

Supporting information

Wheat yield in Spain and associated solar radiation patterns

S. Hernandez-Barrera and C. Rodriguez-Puebla

1. CMIP5 models (<https://esgf-data.dkrz.de/projects/esgf-dkrz/>)

Table S1 Models from CMIP5 dataset used in our analysis.

Model acronym	Model Name	Center	Resolution
CCSM4	Community Climate System Model, version 4	National Center of Atmospheric Research (NCAR), USA	0.9° (lat)x 1.25 (lon), L27
CESM1-CAM5	Community Earth System Model version 1 with the Community Atmospheric Model, version 5	National Science Foundation, U.S. Department of Energy, National Center for Atmospheric Research (NSF-DOE-NCAR), USA	0.9° (lat) x 1.25 (lon), L27
CMCC-CESM	Centro Euro-Mediterraneo per I Cambiamenti Climatici Carbon Cycle Earth System Model	Centro Euro-Mediterraneo per I Cambiamenti Climatici (CMCC), Italy	1.875° x 1.875° (T63), L95°
CNRM-CM5	Centre National de Recherches Météorologiques Coupled Global Climate Model, version 5	Centre National de Recherches Meteorologiques (CNRM-CERFACS), France	TL127, L31
CanESM2	Second Generation Canadian Earth System Model	Canadian Centre for Climate Modelling and Analysis (CCCMA), Canada	T63, L35
GFDL-ESM2M	Geophysical Fluid Dynamics Laboratory Earth System Model with Modular Ocean Model, version 4 (MOM4) component	NOAA Geophysical Fluid Dynamics Laboratory (NOAA-GFDL), USA	2.0°(lat) x 2.5° (lon) M45, L24
GISS-E2-H	Goddard Institute for Space Studies Model E2, coupled with Hybrid Coordinate Ocean Model (HYCOM)	National Aeronautics and Space Administration (NASA) Goddard Institute for Space Studies, USA	2.0 (lat) x 2.5 (lon), L40
HadGEM2-CC	Hadley Centre Global Environment Model, version 2, Carbon Cycle	Met Office Hadley Centre (MOHC), UK	1.25° (lat) x 1.875 (lon), N96, L60
HADGEM2-ES	Hadley Centre Global Environment Model, version 2, Earth System	Met Office Hadley Centre (MOHC/INPE), UK	1.25° (lat)x 1.875 (lon), N96, L38
MIROC5	Model for Interdisciplinary Research on Climate, version 5	National Institute for Environmental Studies and Japan Agency for Marine-Earth Science and Technology, Japan	1.40625° x 1.40625°, T85, L40
MPI-ESM-MR	Max Planck Institute Earth System Model, medium resolution	Max Planck Institute for Meteorology, Germany	1.8° x 1.8°, T63, L95
NorESM1-M	Norwegian Earth System Model, version 1, intermediate resolution.	Norwegian Climate Centre (NCC), Norway	1.9°(lat) x 2.5°(lon), L26

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

2. K-means cluster analysis

We performed K-means cluster analysis to determine patterns of wheat-yield variability. The number of clusters was assigned previously. To evaluate the effective number of clusters, we used silhouette representation, which shows which data lie well within their cluster (Rousseeuw 1987). A high silhouette value indicates the data is well-matched to its own cluster and poorly-matched to neighbouring clusters. Based on the silhouette criterion and result of the function `evalcluster` (average silhouette width) of MATLAB, we determined the optimal clusters. The comparison of the silhouette representation for two and three clusters enabled us to distinguish the most robust number (Figure S1a and 1b). Three clusters give a weaker structure than two clusters although 7 provinces were not well classified. The average silhouette values for the first and second clusters are 0.73 and 0.23, respectively. Figure S2 shows the spatial pattern of each cluster or centroid and each point assignment.

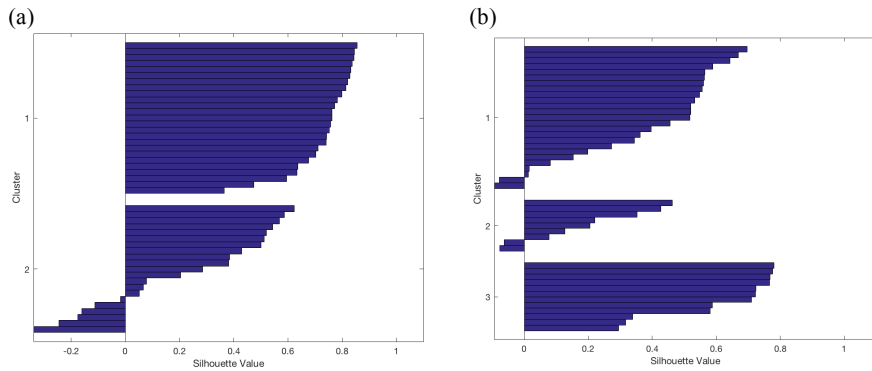


Figure S1. Silhouette representation for two (a) and three (b) prescribed clusters of wheat-yield time series corresponding to the provinces of Spain.




Figure S2. Group of points in each cluster and centroids.

3. Wheat-yield projection

The patterns of PLS regression from the observational period were taken into account, combined with the variables SSRD in SON, DJF, and MAM of each CMIP5 model to derive the simulated PLS components. These PLS components reflect the evolution of the patterns associated with wheat yield given for each CMIP5 SSRD data. We make use of the simulated PLS components to project wheat yield using the regression coefficients of the proposed empirical wheat-yield model. Figure S3 show the simulations for each individual model in different colours for regions 1(a) and 2 (b). The black line represents the multi-model ensemble and the grey shaded area represents the spread of all simulations. From these time series, the trend time series were filtered out using EEMD approach. The trend time series are represented in Figure 5.

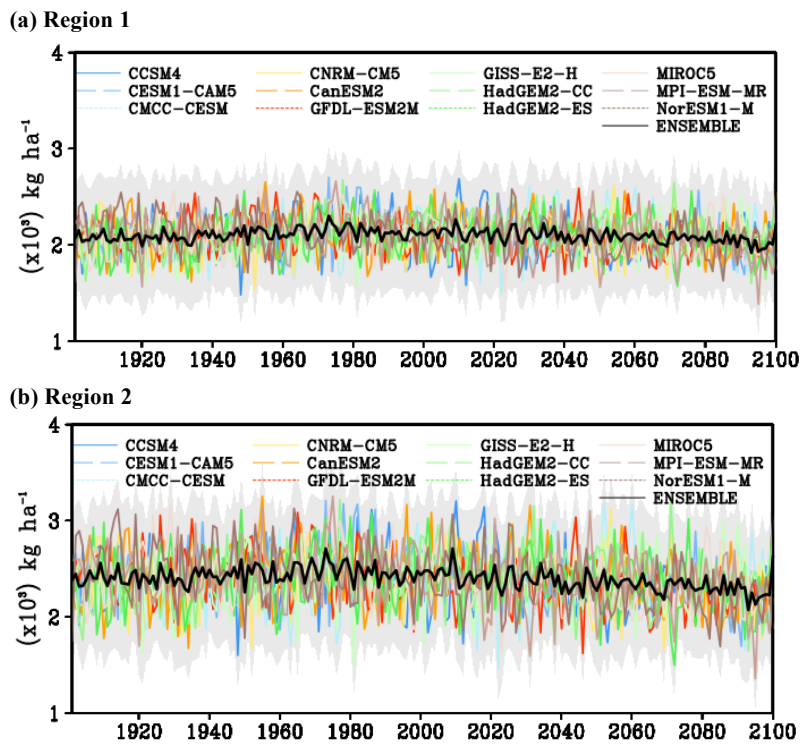


Figure S3. Time series of wheat yield simulated with each model and the multi-model ensemble in region 1 (a) and region 2 (b). The grey shaded area represents the spread of all simulations.

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

4.1 Climate-yield relationships in Spain

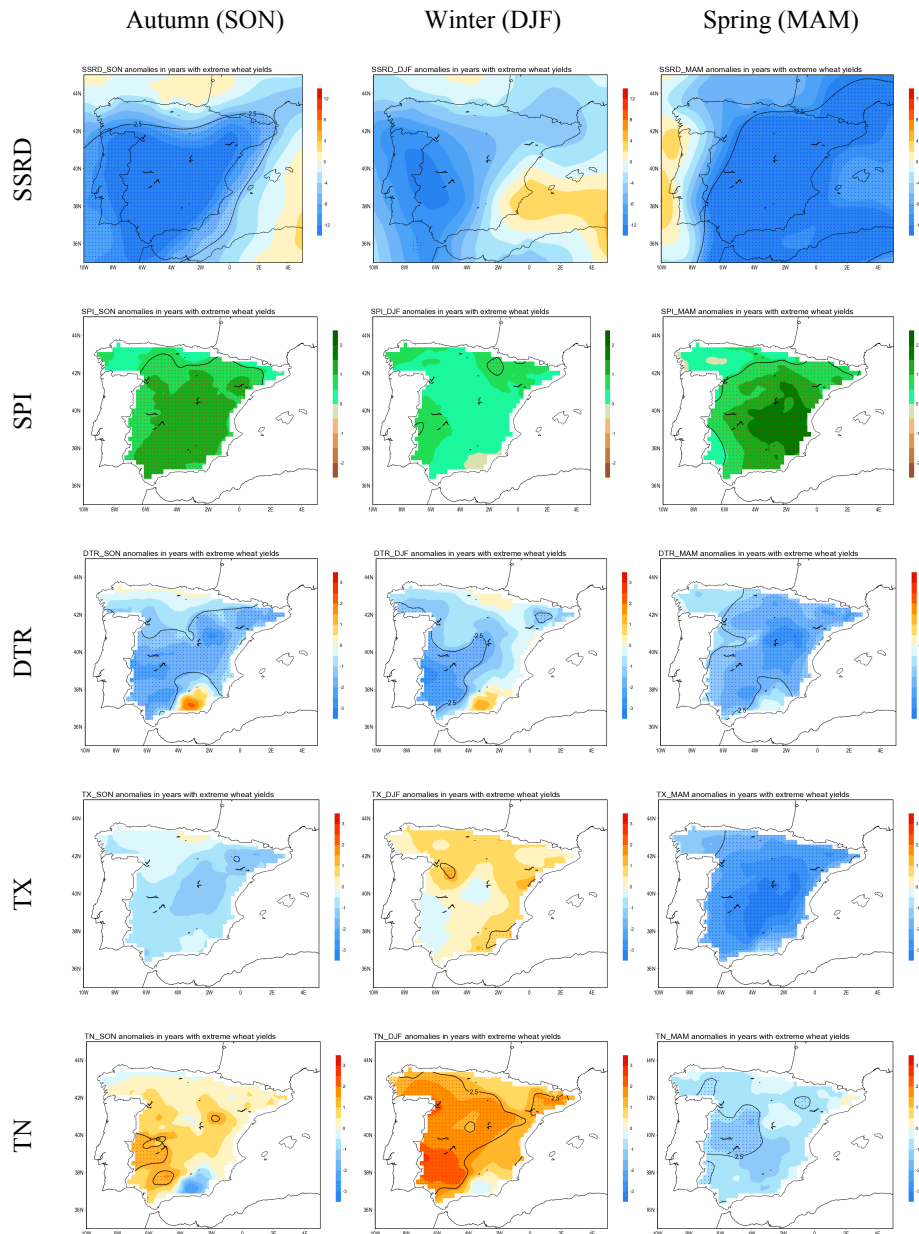


Figure S4. All panels show composite maps of the difference of the climate variables SSRD, SPI, DTR, TX and TN, in autumn, winter and spring for years with extreme wheat yield.

4.2 Association between SSRD and climate variables

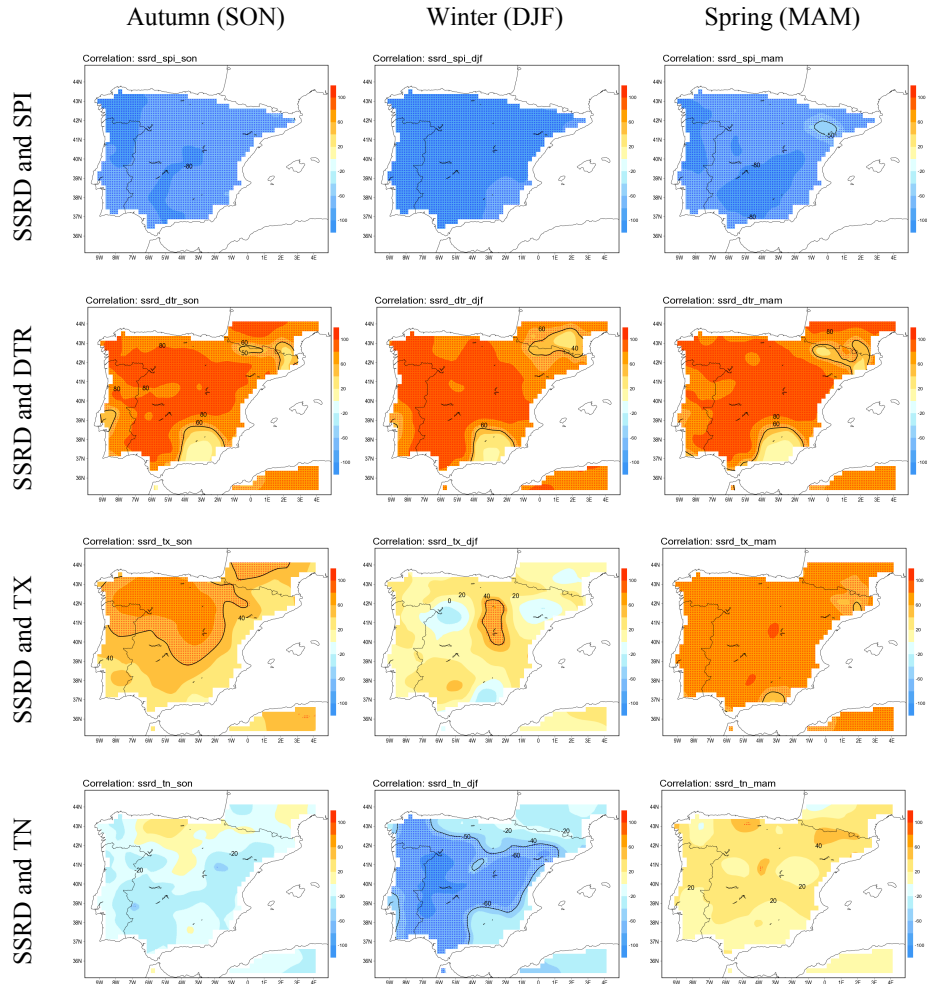


Figure S5. All panels show regression patterns between surface solar radiation (SSRD) and climate variables: Standardized precipitation index (SPI), diurnal temperature range (DTR), maximum temperature (TX) and minimum temperature (TN). In autumn (SON), winter (DJF) and spring (MAM).

4.3 Comparison of models based on surface solar radiation (SSRD) against those based on standardised precipitation index (SPI) and diurnal temperature range (DTR)

A comparison of the performance of models proposed here with the previous model based on the variables' SPI and DTR (HB2016) is provided by means of the correlation coefficients between the variables included in the models and the observed wheat yield, and also between estimated and observed wheat yield. Table S2 shows the greater influence in case of the PLS components of SSRD than the PLS components corresponding to SPI and DTR. The wheat

5.2. Artículo “El rendimiento del trigo en España y su asociación con los patrones de radiación solar”

yield estimated correlated more significantly with the observation for the model based on SSRD than when is based on SPI and DTR.

Table S2. (a) Correlations between wheat yield in regions 1 and 2 with the PLS components of SSRD in autumn, winter, and spring, and the proposed models (MODEL SSRD); b) Same for the PLS components of SPI and DTR and the proposed models using SPI and DTR.

(a)	PLS_SSRD SON	PLS_SSRD DJF	PLS_SSRD MAM	MODEL SSRD
Region 1	-0.791 ±0.063	-0.728 ±0.077	-0.785 ±0.062	0.899 ±0.031
Region 2	-0.752 ±0.065	-0.835 ±0.051	-0.769±0.064	0.937 ±0.020

(b)	PLS_SPI SON	PLS_DTR DJF	PLS_SPI MAM	MODEL SPI and DTR
Region 1	0.443 ±0.126	-0.314 ±0.143	0.767 ±0.087	0.871 ±0.043
Region 2	0.413 ±0.128	-0.467 ±0.127	0.691 ±0.104	0.863 ±0.059

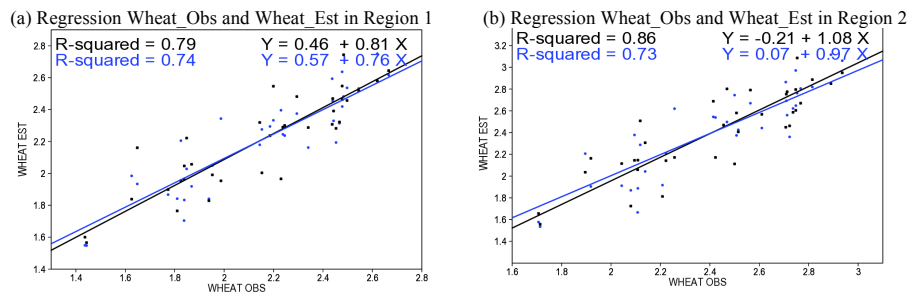


Figure S6. Scattergram of the model based on SSRD (black) and on SPI plus DTR (blue) for the region 1(a) and region 2 (b)

A comparison of the model performance locally at each province for both models is given by the corresponding correlation of Figure S5. We computed the False Discovery Rate (FDR) (Wilks, 2016) to interpret the significance of the correlation map, which give the field significance taking into account the effect of spatial correlation. The critical value (p) will suffer a decrease for a significant level, when there is spatial correlation. The critical p-value at a 95% significance level in case of the model based on SSRD was 0.033, and for the model based on SPI and DTR was 0.022. Consequently, we obtained that 71% of the points were significant in the case of SSRD and 65% in the case of the model based on SPI and DTR.

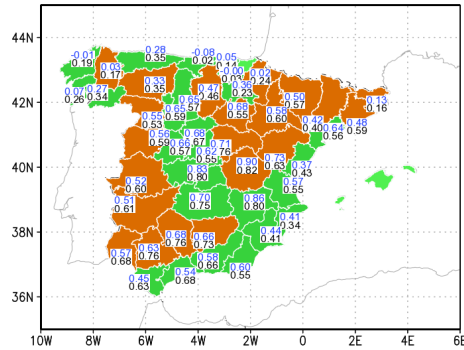


Figure S7. Correlation between estimated and observed wheat yield for each province using the model based on SSRD (black) and the model based on SPI and DTR (blue)

Supporting references

- Rousseeuw, P.J., 1987. Silhouettes - a graphical aid to the interpretation and validation of cluster-analysis. *Journal of Computational and Applied Mathematics*, 20: 53-65
- Wilks DS. 2016. The stippling shows statistically significant gridpoints: How research results are routinely overstated and over-interpreted, and what to do about it. *Bulletin of the American Meteorological Society* (in press)

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

5.3.1. Resumen

El objetivo de este estudio es evaluar la variabilidad del rendimiento de trigo de invierno simulado en España utilizando el modelo “General Large Area Model (GLAM) for annual crops”. El modelo GLAM-trigo se calibró siguiendo los procedimientos de estudios previos, basados en el rendimiento de trigo observado y además, se utilizó una re-calibración de la distribución de percentiles mediante el método “empirical quantile mapping”. GLAM-trigo se evaluó considerando métricas estadísticas y comparaciones entre las respuestas del rendimiento de trigo simulado y observado a los principales factores climáticos. Se encontraron que las mayores diferencias entre los modelos empíricos y GLAM se presentan en años en los que los índices de teleconexión son más intensos. Como el modelo empírico basado en la radiación solar incluye los efectos de las teleconexiones se propone combinar los modelos empíricos y basado en procesos para incluir los efectos de las variables climáticas y teleconexiones. Los resultados se aplican para obtener el impacto del cambio climático en las tendencias del rendimiento de trigo, integrando en GLAM-trigo las salidas de los modelos del proyecto de intercomparación de modelos acoplados de la fase 5 (CMIP5). Los resultados muestran una reducción del rendimiento del trigo en el siglo XXI, de modo que, GLAM-trigo presenta una disminución mayor que los modelos empíricos. Los métodos aplicados en este estudio podrían ser utilizados para predicciones estacionales del rendimiento de trigo y cambio climático.

Palabras clave: Simulaciones GLAM-trigo · Impacto del cambio climático · Tendencia del rendimiento del trigo · Rendimiento de trigo en España

5.3.2. Puntos de partida y recursos

Esta parte de la investigación se plantea porque las investigaciones empí-

ricas deben complementarse con estudios teóricos. Además, con los modelos empíricos se puede reconstruir la variabilidad de la productividad de los cultivos, sin embargo, los estudios sobre sensibilidad de las producciones a los cambios medioambientales requieren modelos dinámicos o basados en procesos. Por lo que, las cuestiones planteadas para desarrollar esta investigación fueron:

1. ¿Es adecuado el modelo de cultivo GLAM para representar la variabilidad del rendimiento de trigo en España?
2. ¿Las simulaciones con GLAM dan cuenta de la influencia de los modos de variabilidad climática de forma similar a como quedaron representadas por el rendimiento de trigo observado?
3. ¿Cuál es la tendencia que proyecta GLAM para el rendimiento de trigo?
4. ¿Cuál es la incertidumbre de las proyecciones de tendencia dada mediante GLAM en comparación con la de los modelos empíricos?

Para llevar a cabo este estudio se utilizaron los datos que se detallan a continuación: datos del rendimiento de trigo de 46 provincias de toda España para el período 1980-2014. Datos diarios, mensuales y estacionales de temperatura máxima (T_{max}) y mínima (T_{min}), precipitación (rr) y radiación solar en superficie ($SSRD$) para el periodo comprendido desde septiembre de 1979 hasta junio de 2014. Los datos de T_{max} , T_{min} y rr se tomaron de los datos pseudo-observados E-OBS con una resolución de 0.25° , y los datos de $SSRD$ del reanálisis ERA-Interim con una resolución de 0.75° , los cuales fueron remallados a la misma resolución que los datos E-OBS. De los datos de precipitación se deriva el índice de precipitación estandarizado (SPI), y de las temperaturas se deriva el rango diurno de temperatura (DTR), como se especifica en el Capítulo 3. Simulaciones de T_{max} , T_{min} y rr y $SSRD$ de 9 modelos CMIP5 (ver Capítulo 3), utilizando las simulaciones “Historical” para el período que abarca desde septiembre de 1951 hasta agosto de 1999 y las “RCP8.5” del siglo XXI. Para el desarrollo de este estudio se han utilizados los siguientes procedimientos:

- ◇ Se obtuvieron simulaciones del rendimiento de trigo mediante el modelo GLAM para el período 1997-2014. Como se indica en el Capítulo 4, GLAM es un modelo agrícola basado en procesos a escala regional (Challinor et al. 2004), que puede utilizarse para cuantificar los impactos de

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

la variabilidad del clima y los cambios de los cultivos. En este estudio se aplica la versión de GLAM para el trigo de invierno (GLAM-trigo; Li 2008, Challinor et al. 2010). Primero se realiza la optimización del rendimiento del trigo sobre las dos regiones, en las que se clasificó el trigo en España, según se ha mostrado en la sección anterior. Los parámetros obtenidos en la optimización se utilizan para calibrar el modelo, para simular el rendimiento de trigo y para proyectar el rendimiento del trigo mediante las salidas de los modelos climáticos. Una vez obtenidos los parámetros de optimización de las dos regiones, se calibró GLAM en cada provincia para el período de calibración 1980-1996. La calibración se realiza determinando el YGP correspondiente a la minimización del estadístico RMSE entre el rendimiento observado y el simulado. Además, se aplica una re-calibración ajustando la distribución de percentiles de las simulaciones obtenidas en cada provincia con respecto al rendimiento de trigo observado. Para ello, se ha utilizado el método “Empirical quantile mapping” (eQM; ver Capítulo 4). Este método también se utiliza para eliminar los sesgos de distribución en las proyecciones obtenidas con GLAM-trigo, para el ajuste de frecuencia se considera el período observado (1980-2014) y para la extrapolación del rendimiento de trigo el período 2015-2099.

- ◇ La evaluación de GLAM se llevó a cabo de dos maneras. Por un lado, se utiliza la correlación lineal de Pearson entre las simulaciones y observaciones (R) para cuantificar la variabilidad, la raíz cuadrada del error cuadrático medio (RMSE) para estimar la desviación de la amplitud de las simulaciones respecto a la observación, y la desviación estándar relativa para medir la capacidad de las simulaciones para reproducir la variabilidad. Para obtener los niveles de significación de los mapas de correlación (ver Capítulo 4) teniendo en cuenta la correlación espacial se utiliza la tasa de falso descubrimiento (FRD). Y por otra, se analiza la respuesta de GLAM a las variables climáticas que incluyen los modelos empíricos. Para ello se aplican los métodos utilizados en las investigaciones anteriores: la regresión por mínimos cuadrados parciales (PLS) y un modelo de regresión múltiple lineal con selección de predictores, para evaluar el efecto de los factores climáticos sobre el rendimiento del trigo.
- ◇ Además, se aplica el método de descomposición empírica en modos por conjuntos (EEMD), para extraer las tendencias de las proyecciones, y

para cuantificarlas y medir su significación se utiliza la prueba de Sen y Mann-Kendall, respectivamente. Así mismo, se ha cuantificado la incertidumbre de las proyecciones mediante el cálculo del índice SNR (ver Capítulo 4).

5.3.3. Discusión y conclusiones

Evaluación de las simulaciones de GLAM-trigo en España.

Las simulaciones de GLAM se comparan con el rendimiento de trigo observado en cada provincia. La habilidad del modelo se mide mediante el cálculo de los coeficientes de correlación (R) y el RMSE, como se muestra en la Figura 5.15a. Además, las áreas que muestran un patrón de correlación significativo están representadas mediante puntos, el nivel de significación se obtuvo con el método FDR. Por lo que, sólo se encontraron relaciones significativas en las provincias de Sevilla (SV), Córdoba (CO), Zaragoza (ZG) y Cuenca (CU), las cuales pertenecen a la región 2. Sin embargo, tras aplicar la corrección de sesgo eQM el nivel de significación mejora del 13% al 57%, a un nivel de significación global del 5% (Figura 5.15b). Así mismo, se examinan las diferencias entre las simulaciones de GLAM respecto al rendimiento del trigo observado de las dos regiones en las que el trigo fue clasificado en función de su variabilidad, mediante un diagrama de Taylor (Figura 5.16). Mediante un examen visual, y según las métricas representadas en el diagrama, las simulaciones muestran un mayor acuerdo con el trigo observado en las provincias pertenecientes a la región 2, además, la habilidad de GLAM-trigo mejora para el promedio del rendimiento de trigo de las regiones 1 y 2.

La Figura 5.17a, la Figura 5.17b y la Figura 5.17c muestran la evolución del promedio de las simulaciones de trigo para España y las regiones 1 y 2, respectivamente, junto con las correspondientes observaciones. El acuerdo es superior en la región 2, como así lo indica el coeficiente de correlación (R). La línea negra muestra la diferencia o el sesgo entre el rendimiento de trigo simulado y observado. Se puede observar en la Figura 5.17a que los mayores sesgos positivos (sesgos negativos) entre el rendimiento de trigo simulado y observado corresponde con los años 1981, 1983, 2010 y 2014 (1999 y 2008). Estos años corresponden con los años más intensos del índice ENSO, excepto el 2010 que corresponde con una fuerte fase negativa de la NAO. Por lo que, algunas de las discrepancias entre el rendimiento de trigo simulado y observado

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

podrían deberse a los patrones de teleconexiones. Por otra parte, algunos autores (Gimeno et al. 2002, Capa-Morocho et al. 2016, Cantelaube et al. 2004, Rodríguez-Puebla et al. 2007), demostraron los efectos del ENSO y la NAO en los cultivos de España.

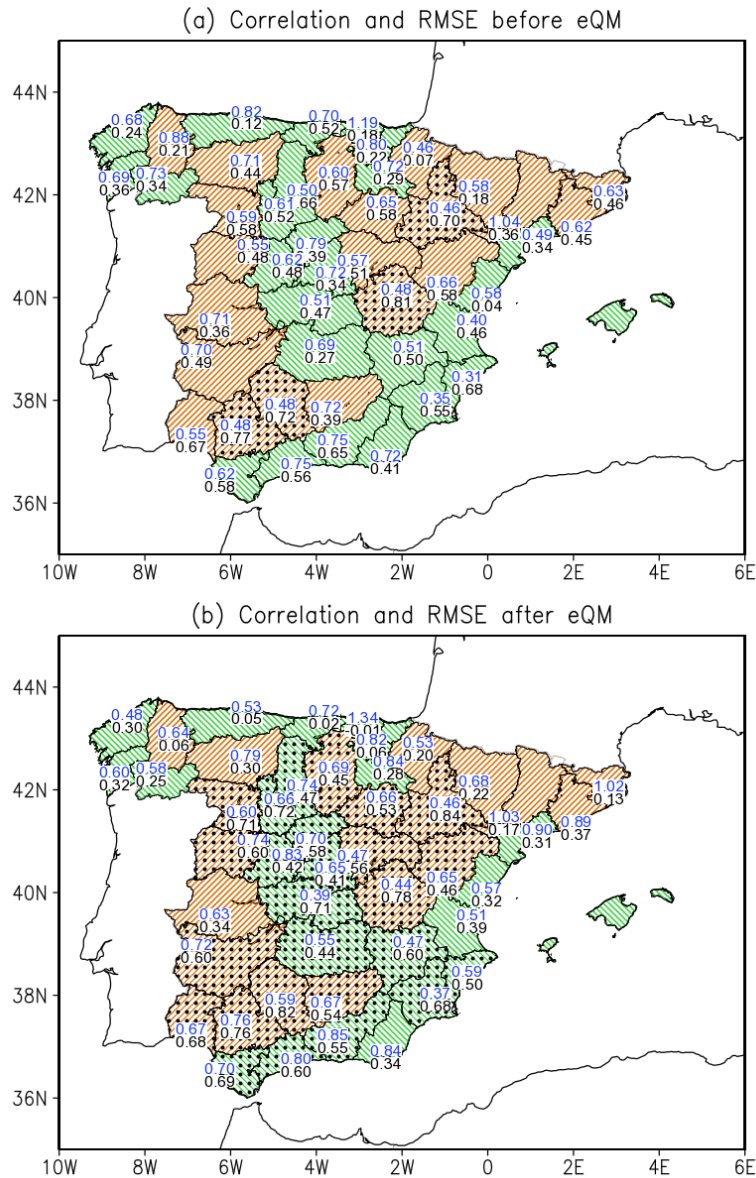


Figura 5.15: a) Correlación lineal (números negros) y error cuadrático medio (10^3 kg ha^{-1}) (RMSE) (números azules) entre el rendimiento de trigo simulado con GLAM y el observado.

Los puntos indican las áreas en las que la correlación es espacialmente significativa de acuerdo con la métrica FDR. Los patrones marrón y verde indican las dos regiones de trigo.

b) Las mismas métricas estadísticas después de la re-calibración aplicando eQM




Figura 5.16: Diagrama de Taylor que muestra la habilidad de GLAM-trigo en cada provincia y en las regiones 1 (verde) y 2 (marrón). La referencia es la desviación estándar normalizada del rendimiento de trigo observado. Las desviaciones estándar de las simulaciones respecto a las observaciones. Los puntos 1 y 2 indican dónde se localizan las simulaciones para las regiones 1 y 2. Las líneas circulares sólidas representan la diferencia RMSE con un intervalo de 0,25

Evaluación de las relaciones clima-trigo simulado. Una cuestión planteada es: ¿Cuál es la respuesta de las simulaciones del rendimiento de trigo obtenidas con GLAM a los factores climáticos que caracterizan el rendimiento de trigo observado encontrados en estudios previos (Hernández-Barrera et al. 2016, Hernández-Barrera & Rodríguez-Puebla 2017)?

Para obtener estas relaciones se aplica la regresión PLS, del mismo modo que en los estudios previos. Por un lado, se obtienen las relaciones entre el rendimiento del trigo simulado por GLAM y el SPI en otoño y primavera, y el DTR en invierno. Y por otro lado, se estima la influencia de la SSRD en otoño, invierno y primavera. Las componentes obtenidas tras aplicar la regresión PLS, se combinan mediante la regresión lineal paso a paso para estimar la variabilidad del rendimiento del trigo. Por lo tanto, se combinan los modelos empíricos y los basados en procesos para investigar las discrepancias entre el rendimiento de trigo observado y simulado. Los resultados obtenidos se muestran en las Tablas 5.3 y 5.4 para el rendimiento de trigo observado (OBS-trigo) y el rendimiento de trigo simulado (GLAM-trigo), respectivamente. De manera que los coeficientes de regresión (a, b, y c) indican los efectos de las diferentes variables en el rendimiento de trigo. La SSRD produce un efecto negativo al igual que el DTR y el SPI tiene una influencia positiva. Los resultados son consistentes para las simulaciones y observaciones. Además, según los valores de

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

R^2 , el modelo empírico basado en SSRD explica más variabilidad del trigo que en modelo basado en SPI y DTR en las dos regiones, tanto para el rendimiento observado como el simulado con GLAM.

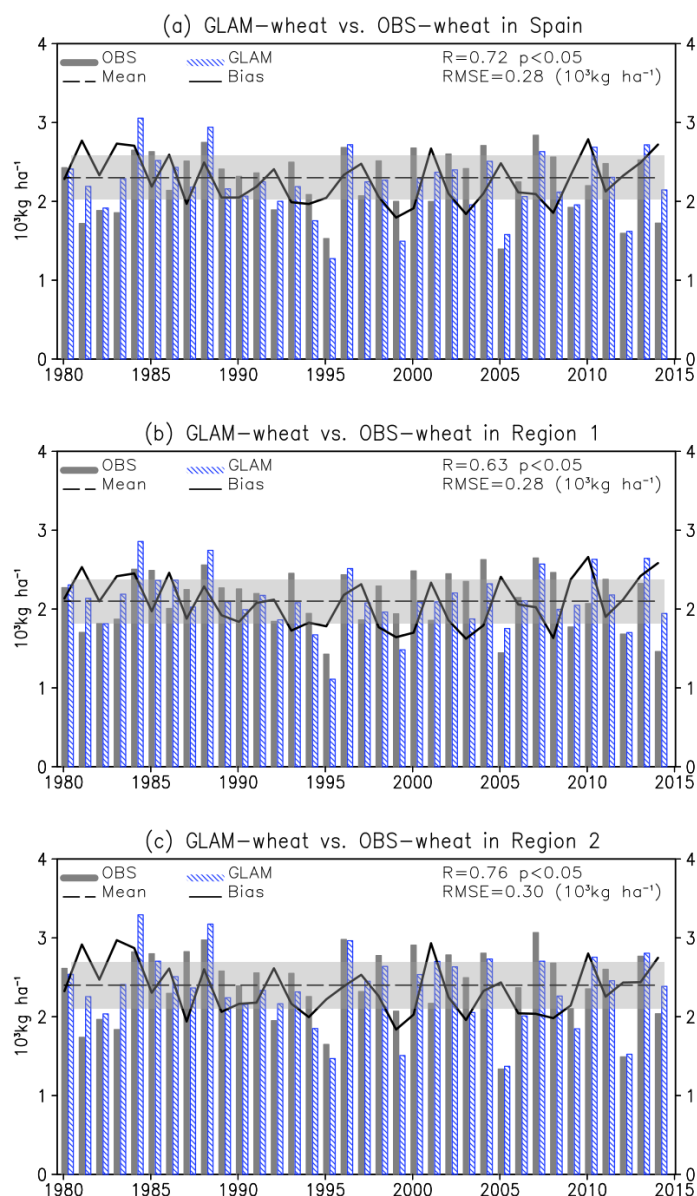


Figura 5.17: Series temporales del rendimiento de trigo observado (barras grises) y el simulado por GLAM (barras de líneas azules) para España (a), la región 1 (b) y la región 2 (c). La línea negra corresponde con el sesgo entre en el rendimiento de trigo simulado por GLAM y el observado. La línea gris corresponde con en el rendimiento de trigo medio y la zona sombreada corresponde con el RMSE

Tabla 5.3: Evaluación del modelo lineal entre el rendimiento de trigo observado (OBS) y simulado (GLAM) y las componentes PLS de la SSRD, utilizando las siguientes métricas: el coeficiente de determinación antes (R^2)($p < 0.05$) y después (R^2_{CV}) de aplicar la validación cruzada; la raíz cuadrada del error cuadrático medio (RMSE). Los parámetros de los coeficientes de regresión (a, b y c) indican la contribución relativa de la SSRD en cada estación del ciclo vegetativo del rendimiento de trigo para las regiones 1 y 2, el nivel de significación se muestra entre paréntesis, caracterizado por el valor de p (*no significativo)

		R^2	R^2_{CV}	RMSE	a	b	c
GLAM-trigo	Región 1	0.86	0.85	0.14	-0.10 (0.014)	-0.11 ($2 \cdot 10^{-4}$)	-0.18 ($3 \cdot 10^{-5}$)
	Región 2	0.71	0.68	0.26	-0.041 (0.57)*	-0.13 (0.017)	-0.27 ($4,5 \cdot 10^{-4}$)
OBS-trigo	Región 1	0.85	0.84	0.14	-0.12 (0.003)	-0.14 ($8 \cdot 10^{-4}$)	-0.10 (0.008)
	Región 2	0.88	0.86	0.17	-0.10 (0.025)	-0.27 ($1 \cdot 10^{-5}$)	-0.10 (0.021)

Tabla 5.4: Evaluación del modelo lineal entre el rendimiento de trigo observado (OBS) y simulado (GLAM) y las componentes PLS del índice de precipitación estandarizado (SPI) y del rango diario de temperatura (DTR), utilizando las siguientes métricas: el coeficiente de determinación antes (R^2)($p < 0.05$) y después (R^2_{CV}) de aplicar la validación cruzada; la raíz cuadrada del error cuadrático medio (RMSE). Los parámetros de los coeficientes de regresión (a, b y c) indican la contribución relativa del SPI y DRT en cada estación del ciclo vegetativo del rendimiento de trigo para las regiones 1 y 2, el nivel de significación se muestra entre paréntesis, caracterizado por el valor de p (*no significativo)

		R^2	R^2_{CV}	RMSE	a	b	c
GLAM-trigo	Región 1	0.66	0.61	0.22	0.025 (0.51)*	-0.17 ($1,1 \cdot 10^{-4}$)	0.23 ($1 \cdot 10^{-6}$)
	Región 2	0.71	0.67	0.26	0.08 (0.086)*	-0.23 ($1,8 \cdot 10^{-6}$)	0.29 ($1 \cdot 10^{-6}$)
OBS-trigo	Región 1	0.75	0.72	0.18	0.11 (0.0019)	-0.08 (0.012)	0.25 (0.000)
	Región 2	0.74	0.71	0.24	0.14 (0.0021)	-0.18 ($1,2 \cdot 10^{-4}$)	0.27 (0.000)

Además, para ilustrar las diferentes respuestas del rendimiento de trigo observado y el simulado por GLAM a las influencias de las variables climáticas se utiliza el diagrama de dispersión (Figura 5.18). Estos diagramas muestran

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

cómo responde el rendimiento de trigo observado y simulado por GLAM a las componentes individuales PLS de las variables climáticas incluidas en los modelos empíricos, donde los resultados para la región 1 (región 2) se muestran en verde (marrón). En general, las simulaciones de GLAM son capaces de capturar la variabilidad climática estacional, con una respuesta mayor (menor) a la SSRD (SPI) en primavera; con una respuesta baja (alta) a la SSRD (DTR) en invierno; y con una respuesta prácticamente insignificante a la SSRD y SPI en la región 2 en otoño. Estos resultados están de acuerdo con Ben-Ari et al. (2016) e Iglesias et al. (2012) que encontraron que la sequía sirve como indicador para predecir las pérdidas del rendimiento de trigo en España.

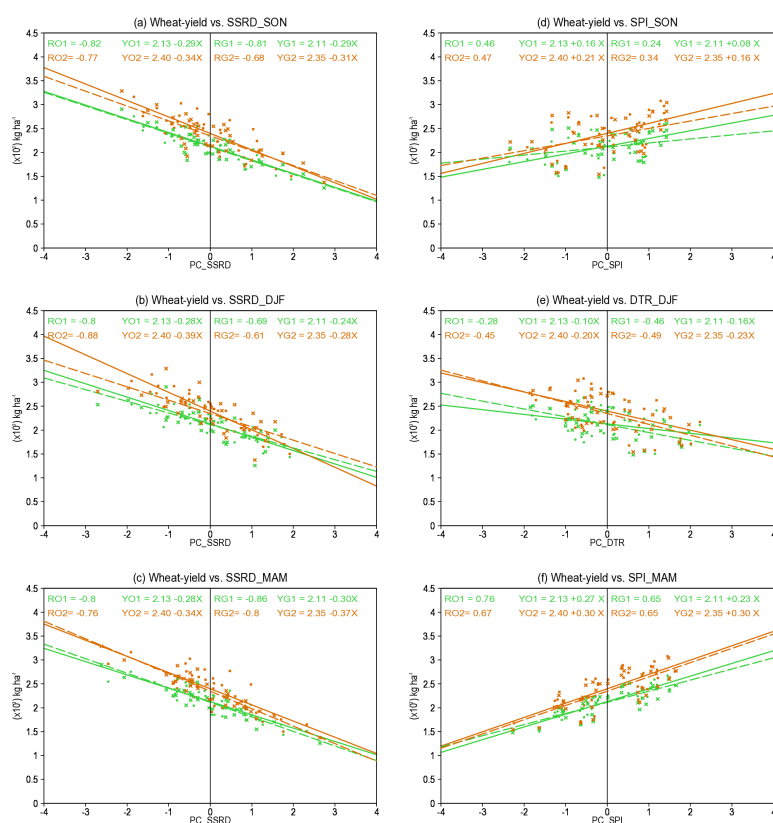


Figura 5.18: Diagrama de dispersión que muestran las respuesta del rendimiento de trigo a los diferentes factores climáticos o componentes PLS: radiación solar (SSRD) (a, b, c); índice de precipitación estandarizado (SPI) (d y f); rango diario de temperatura (e) para la región 1 (verde) y región 2 (marrón). R01(2) y RG1(2) son los coeficientes de corrección entre la componente PLS_SSRD y el OBS-trigo y GLAM-trigo, respectivamente. Y01(2) y YG1(2) son las ecuaciones de regresión para el OBS-trigo y GLAM-trigo, respectivamente, donde X representa las componentes PLS. Las líneas continuas y los puntos caracterizan el ajuste en el caso OBS-trigo, y las líneas discontinuas y las cruces caracterizan el ajuste en el caso GLAM-trigo

Evaluación de las relaciones teleconexiones-trigo simulado.

Los impactos del ENSO sobre el rendimiento de trigo en España, tanto para el trigo observado como el simulado por GLAM, han sido analizados basándonos en el artículo de Iizumi et al. 2014. Para ello, se obtienen mapas compuestos de los rendimientos de trigo (observado y simulado) para los años en los que se presentaban el fenómeno del ENSO³ durante el período 1980-2014, es decir, para los años del Niño muy fuertes (1982 y 1997) y moderados (1986, 1992 y 2009), y para los eventos de La Niña fuertes (1998) y moderados (1998, 2000, 2007 y 2011). La Figura 5.19a y Figura 5.19b, muestran los mapas compuestos para el

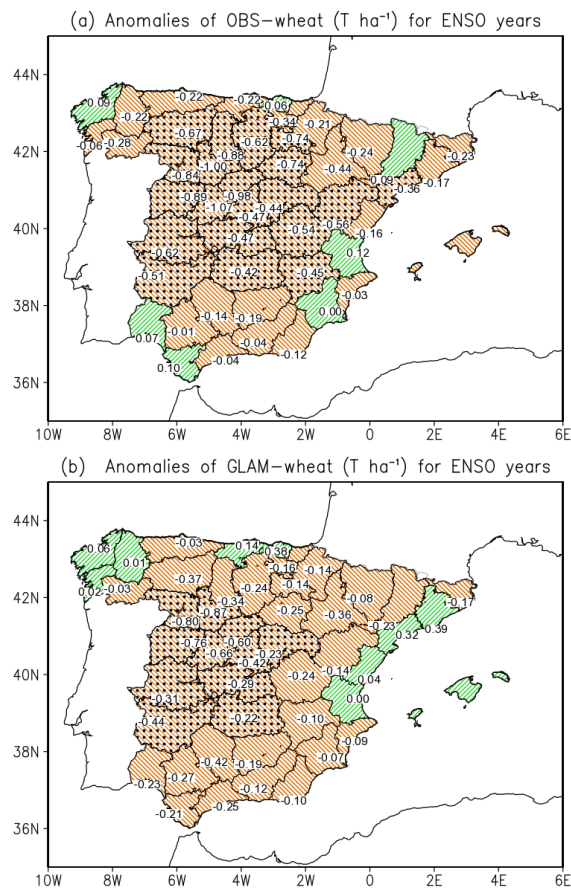


Figura 5.19: Mapas compuestos del rendimiento de trigo para los años del ENSO: usando OBS-trigo (a) y usando GLAM-trigo (b). Los patrones marrones (verdes) indican anomalías negativas (positivas). Los puntos identifican a las provincias donde las diferencias son significativas con un intervalo de confianza >95 % (o nivel de significación $p < 0.05$) basado en la prueba t de Student

³<http://ggweather.com/enso/oni.htm>

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

trigo observado y simulado, respectivamente. Se observa que las mayores anomalías negativas significativas se presentan en el caso del rendimiento de trigo observado, con una significación espacial del 41 % frente al 20 % del simulado por GLAM. Lo que nos indica que GLAM no es capaz de reproducir la intensidad de la variabilidad del trigo asociada con los eventos del ENSO para el período estudiado.

El ENSO se caracteriza por anomalías calientes (frías) de la temperatura superficial del mar en el Pacífico Ecuatorial. Durante la fase caliente se intensifica la evaporación y convección aumentando la temperatura global (Trenberth et al. 2002). Estas señales del ENSO se transmiten al Atlántico mediante alteraciones de la circulación de Walker y Hadley. A la vez se modifica la trayectoria de tormentas y la corriente en chorro subtropical. Como consecuencia se producen anomalías de precipitación y temperatura, que particularmente se detectan también en España (Frías et al. 2010, Palmeiro et al. 2017) mediante las teleconexiones.

Los efectos del ENSO en el trigo se explican porque el ENSO induce anomalías de las variables climáticas que afectan al trigo. Por ejemplo, es interesante observar que en años El Niño disminuye el SPI, o se presentan condiciones más secas y a su vez, aumenta la radiación solar en primavera.

Sin embargo, una cuestión que requiere un estudio detallado es: ¿Por qué GLAM falla en la respuesta al ENSO? Los cultivos son vulnerables a eventos extremos (Lesk et al. 2016, Lobell et al. 2012) y los eventos extremos están asociados a las teleconexiones (Casanueva et al. 2014). Una posible explicación es que GLAM puede no representar los efectos de los extremos y por lo tanto, de las teleconexiones.

Por todo ello, se sugiere combinar el modelo empírico basado en la SSRD y GLAM-trigo para caracterizar la variabilidad del rendimiento de trigo, y así de esta manera, incluir la influencia de los factores climáticos y los efectos de los índices de teleconexión.

Evaluación del modelo híbrido basado en GLAM y el modelo empírico de SSRD. Los modelos basados en procesos y empíricos se elaboran de diferente manera. Por ejemplo, el modelo GLAM utiliza los valores diarios de las variables climáticas, mientras que los modelos empíricos utilizan los promedios mensuales o estacionales. Sin embargo, los resultados demuestran que ambos tipos de modelos no son independientes. Por ello, el modelo híbrido se construye promediando los resultados del modelo GLAM y el empí-

rico basado en SSRD. De manera que, la habilidad de este modelo se evaluó de dos maneras. Primero, se realiza una evaluación espacial a través de las correlaciones y el RMSE entre las simulaciones del modelo híbrido y el rendimiento de trigo observado en cada provincia, como se muestra en la Figura 5.20. Los coeficientes de correlaciones muestran mejoras notables con respecto al modelo GLAM, sin embargo, son similares al modelo empírico basado en la SSRD. De modo que, la significación espacial es del 89% para el modelo híbrido, para el modelo empírico es del 83% y para GLAM es del 53%.

Por otro lado, se realiza una evaluación temporal del modelo híbrido para España y las dos regiones, mostrada en la Figura 5.21. Al igual que en la evaluación espacial, los resultados mejoran considerablemente con respecto a los obtenidos con GLAM (Figura 5.15), ya que este modelo describe un 83% de la varianza frente al 52% del modelo de GLAM, sin embargo, el modelo basado en la SSRD representa más varianza, un 90%. A pesar de que el modelo basado en la SSRD estima mejor el rendimiento de trigo en España y en las dos regiones, en este estudio se utiliza el modelo híbrido para proyectar el rendimiento de trigo bajo condiciones de calentamiento ya que incluye las ventajas de los modelos basados en procesos para predecir los cambios en el rendimiento de trigo y los efectos de las teleconexiones.

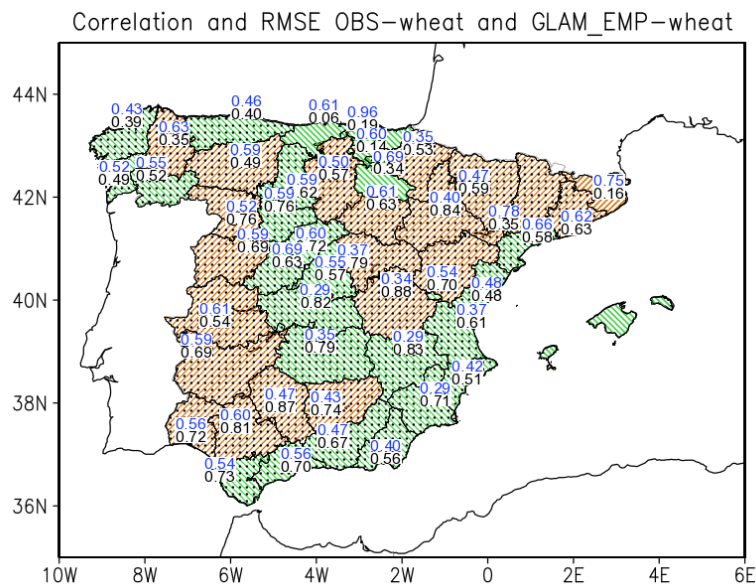


Figura 5.20: Correlación lineal (números negros) y error cuadrático medio (10^3kg ha^{-1}) (RMSE) (números azules) entre el rendimiento de trigo de GLAM_EMP-trigo y OBS-trigo.

Los puntos indican las áreas en las que la correlación es espacialmente significativa de acuerdo con la métrica FDR. Los patrones marrón y verde indican las dos regiones de trigo

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

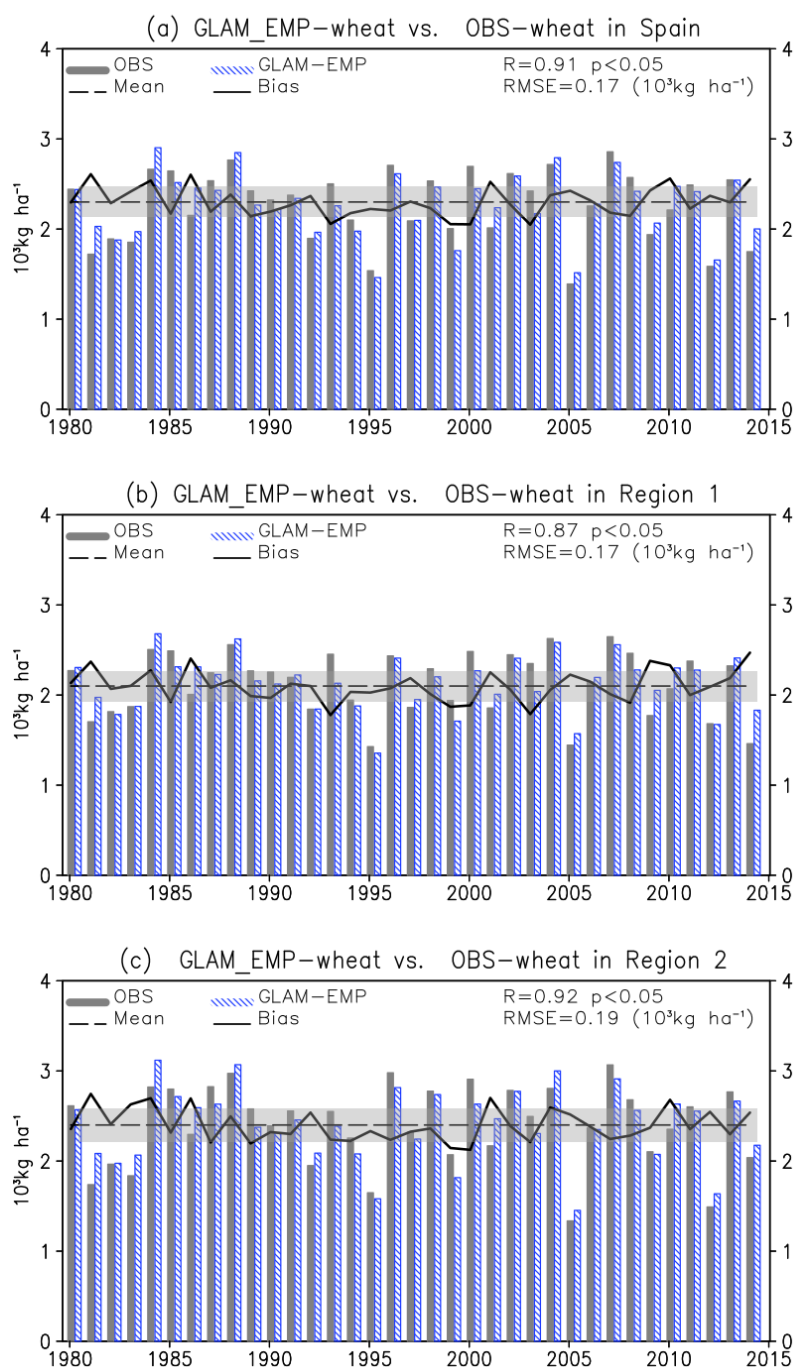


Figura 5.21: Series temporales del rendimiento de trigo observado (barras grises) y el simulado por GLAM_EMP-trigo (barras de líneas azules) para España (a), la región 1 (b) y la región 2 (c). La línea negra corresponde con el sesgo entre en el rendimiento de trigo simulado por GLAM y el observado. La línea gris corresponde con en el rendimiento de trigo medio y la zona sombreada corresponde con el RMSE

Cambios en el rendimiento de trigo combinando el trigo y los modelos CMIP5. Para determinar los impactos del cambio climático en el rendimiento de trigo se comparan las simulaciones del rendimiento de trigo obtenidas con los diferentes modelos (GLAM_EMP-trigo, GLAM-trigo, EMP_SSRD-trigo, EMP_DTR_SPI-trigo), utilizando las salidas de 9 modelos CMIP5. De modo que, esta comparación contribuye a mejorar la confianza de las proyecciones debido a que los modelos climáticos contienen errores (Flato et al. 2013).

Las proyecciones de los modelos empíricos se estiman utilizando el mismo procedimiento de los estudios anteriores en los estudios anteriores (Hernández-Barrera et al. 2016, Hernández-Barrera & Rodríguez-Puebla 2017), sin embargo, los resultados son diferentes ya que en este estudio las proyecciones han sido ajustadas en base a los datos observacionales aplicando eQM. Las proyecciones del modelo híbrido (GLAM_EMP-trigo) se obtienen promediando las proyecciones obtenidas con GLAM y las del modelo empírico basado en la SSRD (EMP_SSRD). Por lo tanto, las tendencias a lo largo del siglo XXI se cuantifican a través del estimador de Sen, y su significación con la prueba de Mann-Kendall Z (ver Capítulo 4). La mayoría de los modelos proyectan una disminución en el rendimiento de trigo, como se muestra en la Tabla 5.5. En el caso del multimodelo, los resultados indican una disminución relativa con respecto al rendimiento medio del trigo aproximada del 42 % para el modelo GLAM-trigo, del 25 % para el modelo GLAM-EMP-trigo y para los modelos empíricos, EMP_SSRD-trigo y EMP-DTR_SPI, del 13 % y 8 %, respectivamente. Estas diferencias pueden deberse a las incertidumbres que introducen los datos de entrada de los modelos CMIP5 (Watson et al. 2015). Por lo que, para obtener la incertidumbre de las proyecciones se obtuvo la relación señal/ruido (SNR) (ver Capítulo 4), cuantificando la contribución de la variabilidad forzada con respecto a la variabilidad no forzada de los modelos. En la Tabla 5.5, se muestra la SNR de los diferentes modelos (GLAM_EMP-trigo, GLAM-trigo, EMP_SSRD-trigo, EMP_DTR_SPI-trigo) para las proyecciones del siglo XXI. De manera que, la SNR más robusta se obtiene para el modelo GLAM-trigo (-3.8) y el modelo híbrido (-2.9), siendo más pequeña para los modelos empíricos.

Para visualizar estos cambios, en las Figura 5.22a y Figura 5.22b se muestran las proyecciones del rendimiento de trigo en España para los modelos GLAM-trigo y GLAM_EMP-trigo, respectivamente, y sus tendencias (Figura 5.22d y Figura 5.22c) obtenidas, aplicando el método EEMD. La mayoría

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

de los modelos presentan una tendencia decreciente, siendo más pronunciadas para el modelo GLAM-trigo.

Tabla 5.5: Cambios en el rendimiento de trigo (10^3 kg/100yrs) a lo largo del siglo XXI para España usando el estimador de Sen (Sen) y el test de Man-Kendall (Z) para la significación, para todos los modelos individuales y el multimodelo. El cambio relativo y la señal/ruido (SNR) se han obtenido para el multimodelo

Model	GLAM		GLAM_EMP		EMP_SSRD		EMP_DTR_SPI	
	SEN	Z	SEN	Z	SEN	Z	SEN	Z
CCSM4	-1.0	-6.9	-0.5	-5.1	-0.06	-1.1	-0.4	-1.8
CMCC-CESM	-0.3	-4.1	-0.2	-1.9	0.06	0.6	-0.3	-3.9
CNRM-CM5	-1.4	-6.9	-1.0	-8.4	-0.6	-3.4	-0.1	-1.0
GFDL-ESM2M	-1.0	-7.9	-0.7	-5.6	-0.2	-2.2	-0.04	-0.2
HadGEM2-CC	-0.9	-5.5	-0.7	-6.4	-0.3	-2.4	-0.04	-0.02
HadGEM2-ES	-1.0	-5.0	-0.7	-5.5	-0.4	-3.4	-0.3	-1.5
MIROC5	-0.9	-13.6	-0.6	-5.6	-0.2	-1.2	-0.04	-0.4
MPI-ESM-MR	-0.7	-6.3	-0.5	-4.7	-0.3	-1.4	-0.1	-1.3
NorESM1-M	-0.9	-3.4	-0.7	-5.2	-0.4	-2.5	-0.04	-0.8
MM-ENSEMBLE	-1.0	-11.0	-0.67	-9.8	-0.3	-4.5	-0.2	-2.5
Relative change	-42 %		-25 %		-13 %		-8 %	
SNR	-3.8		-2.9		-1.4		-1.1	

Otra manera de obtener los cambios en el rendimiento de trigo, bajo condiciones de calentamiento, es comparando la distribución de probabilidad del rendimiento del trigo en diferentes períodos usando un diagrama de cajas. La Figura 5.23a y la Figura 5.23b muestra los resultados de los modelos individuales y del multimodelo para un período observacional (1980-2014) y para un período de proyección futura (2070-2099) para los modelos GLAM-trigo y GLAM_EMP-trigo, respectivamente. Se observa que para el período observacional la distribución del rendimiento de trigo presenta cierta similitud debido al ajuste realizado al rendimiento de trigo observado aplicando eQM, en ambos modelos. Sin embargo, las distribuciones para el clima futuro predicen una disminución en la mediana en todos los modelos. Por lo tanto, la reducción del rendimiento del trigo puede ser interpretada como una consecuencia del calentamiento y por la sequía sufrida en el sur de Europa (Kröner et al. 2017).




Figura 5.22: Proyecciones del rendimiento de trigo para los diferentes modelos CMIP5: usando el modelo GLAM-trigo (a) y el modelo GLAM_EMP-trigo (b). Y las tendencias filtradas de las proyecciones del rendimiento de trigo para GLAM-trigo (c) y para GLAM_EMP-trigo (d)

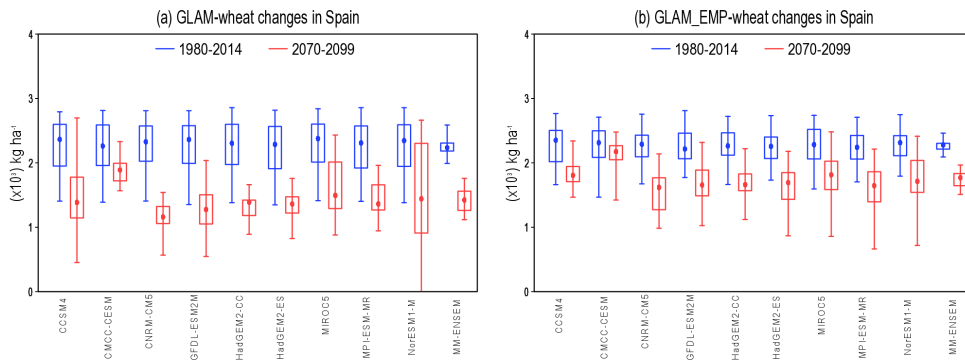


Figura 5.23: Diagrama de Cajas que compara los rendimientos de trigo obtenidos a partir de las salidas de los modelos CMIP5. En cada diagrama están representadas la distribución de probabilidad del rendimiento para el período de observación 1979-2014 (azul) y para el período de proyección 2070-2099 (rojo) para el modelo GLAM-trigo (a) y GLAM_EMP-trigo (b). En cada caja, el punto indica la mediana de la distribución, los bordes superiores o inferiores de la caja indican los percentiles 75 y 25, respectivamente, y las barras superiores e inferiores corresponden a los valores extremos

5.3.4. Article “Assessing GLAM-wheat simulation to estimate variability and projected trend of wheat yield in Spain” and Supplementary Material

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

Assessing GLAM-wheat simulation to estimate variability and projected trend of wheat yield in Spain

Sara Hernandez-Barrera¹, Concepción Rodríguez-Puebla¹, Stewart Jennings², and Andrew J. Challinor²

¹*Department of Fundamental Physics, University of Salamanca, 37008 Salamanca, Spain*

²*ICAS, University of Leeds, Leeds, LS2 9JT, UK*

Abstract

This study aims to assess the variability of winter wheat-yield in Spain simulated with the General Large Area Model (GLAM) for annual crops. We calibrate GLAM-wheat following the methods of previous studies on the basis of the wheat-yield observed and, in addition, by using a re-calibration of the frequency distribution by the empirical quantile mapping approach. The GLAM-wheat evaluation considers statistical metrics and comparisons between responses of the simulated and observed wheat yield to main climate drivers. It was found that some of the differences arise from the effects of teleconnection indices. Therefore, we suggest combining both empirical and process models to include the response of wheat-yield to climate drivers and teleconnections. We apply the results to obtain the impact of climate change on the wheat-yield trend by integrating the outputs of the General Circulation Models of the Coupled Model Intercomparison Project Phase 5 (CMIP5) into GLAM-wheat. The findings show a decrease in wheat yield through the twenty-first century with greater changes shown by GLAM-wheat than by the empirical approaches. The methods used in this study could have relevance for wheat-yield seasonal and climate change predictions.

Keywords: GLAM-wheat simulation; climate change impact; wheat yield trend; wheat yield in Spain.

Highlights:

- GLAM-wheat is evaluated against OBS-wheat considering the effects of surface solar radiation, drought and diurnal temperature range.
- Some discrepancies between GLAM-wheat and OBS-wheat arise from different responses to the ENSO teleconnection.
- GLAM and empirical models are combined to project wheat yield in the 21st century, showing a decrease in yields of about 25%.

1 Introduction

Although climate is not the only factor that affects crops, different studies have found that climate variability and change have strong impact on crop productivity (Gornall et al., 2010; IPCC, 2014; Lobell and Gourdjji, 2012; Lobell et al., 2011a; Moriondo et al., 2010; Thornton and Ewert, 2014). Moreover, climate change represents a major concern for future food production, particularly in the regions most frequently affected by weather disasters such as droughts, flood and extreme heat (Lesk et al., 2016; Lobell et al., 2008; Lobell et al., 2011b; Parry et al., 2005; Rosenzweig and Parry, 1994). With climate change set to intensify throughout the twenty-first-century, countries need to adapt to new situations (Auffhammer and Schlenker, 2014; Slingo et al., 2005). Over the last few decades, technological progress in agriculture has helped to compensate for the negative effects of climate change on crop yields (Asseng et al., 2015; Challinor et al., 2009; Eitzinger et al., 2009; Ewert et al., 2006; Falloon and Betts, 2010; Finger, 2010; Garrigos et al., 2017; Lobell and Field, 2007; Long et al., 2006; Trnka et al., 2011). However, energy resources to produce fertilizer, as well as land and water resources, are limited (Foley et al., 2007; Harris and Kennedy, 1999).

Process-based and empirical models are necessary to evaluate the impact of climate change on crop production (Challinor et al., 2014b; Challinor et al., 2004; Lobell and Burke, 2010; Moore and Lobell, 2014; Porter and Semenov, 2005; Ramirez-Villegas et al., 2013; Semenov and Porter, 1995; Watson et al., 2015). Process-based crop models are useful mainly for determining the causes of yield variation (Ewert et al., 2015; Rotter et al., 2011), for example, the effects of heat and drought stress on crop duration (Challinor et al., 2016), while empirical models are mainly used to characterize crop yield variability under the influence of

climate (Hawkins et al., 2013; Lobell and Asner, 2003; Lobell and Field, 2007; Makowski et al., 2015; Tao et al., 2008).

The PESETA II project (Projection of Economic impacts of climate change in Sectors of the European Union based on bottom-up Analysis) of the JRC (Joint Research Center) projected climate damages to be greater in southern European regions, with a decline of 20% in crop yields by 2080 (Ciscar et al., 2014). Specific studies on potential impacts of climate change in Spain (Iglesias et al., 2012) show that this decline in yields is because of an increase in winter temperature and spring drought. Medina Martin (2015) indicated the need for agroclimatic studies that cover all of Spain to help plan appropriate adaptations actions.

One main question in this study is: how have climate variability and change affected wheat yield in Spain? In previous works, we used empirical winter wheat yield models to determine the effects of regional-scale variables (i.e. drought and diurnal temperature range over Spain) (Hernandez-Barrera et al., 2016 (hereafter HB2016)). Precipitation deficit in spring and autumn and diurnal temperature range in winter were selected to describe wheat yield variability of Spain. However, to project wheat yield in a future climate it is better to use variables from large areas because simulated precipitation from GCMs are subject to great uncertainty and may cause biased of future crop trends (Ceglar et al., 2017; Mearns, 2003; Knutti et al., 2008; Lobell and Burke, 2008; Asseng et al., 2013). Therefore we used large-scale variables (i.e. surface solar radiation over a wide North Atlantic area) (Hernandez-Barrera and Rodriguez-Puebla, 2017 (hereafter HB2017)) to obtain the effects on wheat yield variability. We found that the model based on solar radiation accounts for greater field significance (71%) than the model based on precipitation deficit and diurnal temperature range

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

(65%). In HB2017 we show that the model based on solar radiation accounts for effects of precipitation deficit, diurnal temperature range and also large-scale patterns such as teleconnection indices. The two empirical models predict a decline of wheat yield throughout the 21st century with more confident results in the case of the model based on the links with solar radiation. However, we can not be sure that empirical model extrapolations will be accurate outside of the range on which they are calibrated; the process-based models are useful for predicting future yield changes.

Here, our research has a twofold objective: first to assess the General Large Area Model for annual crops (GLAM) (Challinor et al., 2004) to represent winter wheat-yield variability in Spain and secondly, to use General Circulation Models (GCM) outputs in conjunction with the GLAM model to project the trend of wheat yield with greater confidence compared to the empirical model projections. To reduce uncertainty in the multi-model ensemble, individual models should be evaluated (Maiorano et al. 2016).

Regarding the Wheat Team of the Agricultural Model Inter-comparison and Improvement Project (AgMIP) most of the uncertainty in climate change impact projections is due to structural variations among crop models (Asseng et al., 2013; Challinor et al., 2014a; Jamieson et al., 2007; Landau et al., 1998; Olesen et al., 2000; Palosuo et al., 2011; Porter and Semenov, 1999; Rosenzweig et al., 2013).

The first analysis in this study is the evaluation of GLAM-wheat simulations using wheat-yield observed in individual provinces and in two regions of Spain where wheat yield dataset was averaged because of similar wheat yield variability. The second part of this study examines how wheat yield responds to climate change. To obtain the wheat yield in Spain for the 21st century, we used daily data of surface

solar radiation, precipitation, maximum and minimum temperatures of 9 models from the Coupled Model Intercomparison Project phase 5 (CMIP5) (Taylor et al., 2012), which were integrated into the GLAM-wheat process-based model.

This paper is organized in the following way: section 2 includes the data and methods used, with a brief description of the GLAM process-based crop model; section 3 shows results from the GLAM-wheat calibrations and evaluation, the observed relationships with climate variables and teleconnections, and the projections of wheat yield derived from 9 CMIP5 models. The findings are summarized and discussed in Section 4.

2 Data and Methods

2.1 Wheat-yield observations

We make use of wheat yield (weight of production divided by the cultivation area in 10^3kg ha^{-1}) provided by the Spanish Agriculture, Food and Environment Department (MAGRAMA). The study area involved 46 provinces across Spain for the period 1980 to 2014. Figure 1a shows the study area with the symbols of the provinces considered in the study and their wheat area indicated with different-sized grey circles. Symbols for the locations, other geographic parameters, mean production and area in recent years are specified in supplementary Table S1. The green and brown patterns show regions with similar wheat-yield variability. These regions were classified by applying K-mean cluster analysis to the observed wheat yield. This approach compensates for errors and enhances the signal-to-noise of wheat-yield variability, therefore increasing the goodness of the model fit to the data as reported by Gornott and Wechsung (2016).

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

taken from the daily pseudo-observations E-OBS (version 13.0) dataset at 0.25-degree resolution (Haylock et al., 2008), and ERA-Interim reanalysis (Dee et al., 2011) in the case of SSRD, with 0.75-degree resolution, which we re-gridded to the same resolution of E-OBS by using the bilinear interpolation of the Climate Data Operators (CDO) software package (Schulzweida, 2015). The period considered was the one corresponding to the yield data from September 1979 to June 2014. Observed wheat yield corresponds to irregular domain from individual provinces. Therefore, we averaged the gridded weather data over the area corresponding to each province for the correspondence with wheat yield data. This procedure is different from the one used by Ramirez-Villegas et al., (2015), which gridded the crop data.

To study the responses of the OBS-wheat (observed wheat yield) and GLAM-wheat to the climate variables, we compute the daily diurnal temperature range (DTR) and then the monthly means of TX, TN, RR, DTR, and SSRD. From the monthly RR we obtained drought, represented by the standardized precipitation index (SPI) (Guttman, 1998; Kingston et al., 2015; Vicente-Serrano and Lopez-Moreno, 2005). We then computed the averages in autumn (SON), winter (DJF) and spring (MAM). Then the analysis is performed by using the PLS regression method.

We make use of daily TX, TN, RR, and SSRD of 9 CMIP5 GCMs, which are shown in supplementary Table S2. The dataset was acquired for two time periods, historical simulation of the 20th century (September 1951 to December 2005), and a representative concentration pathway with a radiative forcing of $8.5Wm^{-2}$ (RCP 8.5) from January 2006 to August 2099 (Taylor et al., 2012). As in the case of the E-OBS data, we averaged the CMIP5 data over the provinces and both regions 1 and

2 of the corresponding OBS-wheat. These data were integrated into the GLAM-wheat to provide the wheat yield projections under the climate change scenario. We also compare the changes across two time periods, baseline corresponding to the observational period and future corresponding to the period 2070-2099.

2.3 GLAM crop model

GLAM is a regional-scale process-based crop model (Challinor et al., 2004), which can be applied to quantify the impacts of climate variability and changes on annual crops (Challinor et al., 2005a; Koehler et al., 2013; Ramirez-Villegas and Challinor, 2012; Watson and Challinor, 2013). GLAM combines the benefits of empirical modelling and process-based modelling in order to capture the impacts of sub-seasonal weather variability over large areas. To predict annual winter wheat yield over Spain we applied the GLAM-wheat version used previously to evaluate the impact of climate change on crops in China (Li, 2008; Challinor et al., 2010).

The GLAM-wheat model requires not only daily weather data of RR, TX, TN and SSRD, but also planting date and soil hydrological properties to simulate soil water balance, leaf canopy and root growth, biomass and yield production. GLAM accounts for the impacts on yield due to factors other than weather (pests, diseases and non-optimal management) through a yield gap parameter (YGP), which is constant over time for each site. GLAM’s YGP, together with local soil parameters and weather data will provide the spatial-temporal variability in yield and is less sensitive to errors in input data (Challinor et al., 2005a). In GLAM, the impact of CO₂ concentration on crop growth and yield is simulated through the transpiration efficiency. The model can be run at any spatial resolution and simulates crop growth with a daily time-step. Grain yield (Y)

is estimated from the product of the harvest index and above-ground biomass. The harvest index is limited by high temperature stress, and biomass depends on transpiration and normalised transpiration efficiency.

The GLAM-wheat model was calibrated after Challinor et al., (2004) and, in addition, we have introduced empirical quantile mapping to correct frequency distribution biases. The model parameters were obtained using the GLAM optimiser, which selects optimal values from within predefined ranges (as used in Nicklin K., 2013). In this study, the GLAM optimiser provides parameters for winter wheat in the two regions previously classified by applying K-mean cluster to the observed wheat-yield. These parameters are detailed in supplementary Table S3.

2.4 GLAM calibration and evaluation

Calibration of the model is performed using observed weather data and the parameters from the optimization following previous studies (Challinor et al., 2004; Li, 2008; Challinor et al., 2010). The YGP is adjusted to minimise the RMSE between observed and simulated yield in each province for the period 1980-1996. Supplementary Table S3 provides the model parameters obtained for both regions. Then using the calibrated model we obtained the simulations for the period 1997 to 2014.

The outputs of the GLAM-wheat simulations are evaluated against the corresponding de-trended OBS-wheat in each province. The skill is measured by computing the linear correlation coefficients, which gives the correspondence in variability, and the root mean square errors (in 10^3kg ha^{-1}) to assess the ability of simulation to capture the amplitude of the observations. Note that the correlation coefficient is computed using Fisher Z transformation (Wilks, 2006). To provide the field sig-

nificance of the correlation maps we computed the False Discovery Rate (FDR) (Wilks, 2016), which considers the effect of a correlation decrease at a given significant level when there is spatial correlation. Section 3.1 shows results for the evaluation.

YGP is used to correct the mean bias. However, GLAM outputs show right-skewed (look at Figure S1). GLAM is very highly calibrated when there is not soil water-limited but in regions where there is soil moisture deficit is required eQM re-calibration to correct the right-skewed distribution due to precipitation deficit. We apply a re-calibration by fitting the frequency distribution of GLAM-wheat in each province with respect to the OBS-wheat. Of the different possible methods for correcting these frequency distribution biases (Fang et al., 2015; Sanson et al., 2016) we applied empirical quantile mapping (eQM), following the procedure of variable correction (Dequé, 2007), which is based on the 99 percentiles of the control and observed cumulative distribution function. The period 1980-1997 is used for the eQM and we extrapolated this bias correction for the period 1997-2014. Figure S1 (supplementary material) shows how re-calibration modified the wheat-yield distribution in the case of region 2.

2.5 Comparison of statistical and process-based models on the basis of climate effects

In earlier studies we reported the empirical relationships between OBS-wheat yield with drought, diurnal temperature range and surface solar radiation over two regions in Spain during the growth phases, autumn, winter and spring. The question now is: how can we interpret the GLAM-wheat variability as a response to the same climate drivers that explained the OBS-wheat variability? To address this question we make comparisons between observed

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

and process-based wheat yields, in particular GLAM-wheat, on the basis of the influence of climate variables. These comparisons provide information about the suitability of GLAM-wheat to represent their seasonal climate effects.

To obtain the relationships between GLAM-wheat yield output and climate drivers we performed the same approaches used in our earlier studies (HB2016 and HB2017). On one hand, we estimated the influence of drought, represented by the standardized precipitation index in autumn and spring, and daily temperature range in winter; and on the other hand, we estimated the influence of surface solar radiation throughout autumn, winter and spring. The study is performed independently because climate variables are dependent, i.e. solar radiation is associated with precipitation deficit and diurnal temperature range (HB2017).

The models were computed by using PLS (Partial Least Squares) regression. The PLS approach (Smoliak et al., 2010; Wallace et al., 2012; Wold et al., 2009) provides the climate signals that covariate with wheat yield, then these modes or PLS components can be combined by means of stepwise linear regression (Wilks, 2006) to estimate and explain wheat-yield variability. We then investigated the discrepancies between the different responses of OBS-wheat and GLAM-wheat to climate drivers. The response to surface solar radiation can be described as follows:

$$Y = a \cdot PLS_SSRD_{SON} + b \cdot PLS_SSRD_{DJF} + c \cdot PLS_SSRD_{MAM}$$

where Y corresponds to simulated (observed) wheat yield in each region; PLS_SSRD_{SON} , PLS_SSRD_{DJF} and PLS_SSRD_{MAM} are the PLS components or the time series associated with surface solar radiation in autumn (SON), winter (DJF), and spring (MAM), re-

spectively. Similarly, the response to precipitation (SPI) and diurnal temperature range (DTR) can be described as follows:

$$Y = a \cdot PLS_SPI_{SON} + b \cdot PLS_DTR_{DJF} + c \cdot PLS_SPI_{MAM}$$

where PLS_SPI_{SON} and PLS_SPI_{MAM} are the PLS components or the time series associated with SPI in autumn (SON) and spring (MAM) respectively, and PLS_DTR_{DJF} represents the PLS components or the time series associated with DTR in winter (DJF).

This comparison was performed across regions where wheat yields show similar variability. The wheat yield in the regions averaged the values in the provinces that belong to the areas with similar OBS-wheat variability according to an earlier study (HB2017). Aggregating time series increases the predictive power of the models due to a reduction in the noise of the estimations, as reported by Conradt et al., (2016). The effect of aggregation is justified using a Taylor diagram (Taylor, 2001), which compares the correspondence of simulations against observations, graphically providing the correlation between simulations and observations, standard deviation of simulations relative to the observations and root-mean square difference between simulations and observations for the provinces and regions, as shown in supplementary Figure S2.

We analyse the sensitivities of GLAM-wheat and OBS-wheat to climate drivers or PLS components using scatterplot representations. Then, we determine the different OBS-wheat and GLAM-wheat responses to El Niño/Southern Oscillation (ENSO) by obtaining composite maps of wheat yield for El Niño and La Niña years, following Iizumi et al., (2014).

2.6 Wheat-yield projections under climate change conditions

Our interest in projecting wheat yield in a future climate led us to examine the wheat-yield projections provided by different types of wheat models, i.e. empirical and process-based, using the CMIP5 outputs. We applied GLAM-wheat to determine the yield over Spain using daily data of SSRD, TX, TN and RR, one realization from each of nine CMIP5 models that are depicted in supplementary Table S2 corresponding to the historical and RCP8.5 experiments. The results of GLAM-wheat projections of individual models were post-processed by using eQM to remove distribution biases, considering the observed period 1980-2014 for the frequency adjustment and the period 2015-2099 for extrapolating wheat yield. Some studies indicated that using the eQM correction on the derived climate or impact indices give better performance than to apply eQM to individual CMIP5 data before deriving the indices because in this case lead to physically inconsistent relationships (Casanueva et al., 2016). Therefore, we applied eQM directly to the wheat-yield derived from CMIP5.

In this work, we analysed the trend component of the individual models, which was extracted by applying ensemble empirical mode decomposition (EEMD). The Empirical Mode Decomposition (EMD) is an adaptive approach to decompose a time series into different intrinsic mode functions with different frequencies (Huang et al., 1998). To obtain better signal separation, white noise is added to each EMD process, known as the EEMD method (Chen et al., 2013). We performed the EEMD on the wheat yield derived from each CMIP5 model, and then computed an ensemble of the trend time series. For a detailed application of the method, we refer to our earlier work (HB2016). We quantified the trends with Sen's estima-

tor, gauging their significance with the Mann-Kendall Z test (Sens, 1968; Kendall, 1938).

To quantify the trend uncertainty across the CMIP5 outputs, we obtained a measure of the signal-to-noise ratio (SNR) corresponding to the trend component of wheat-yield projections (Deser et al., 2016). Here we used a simple method to compute the contribution of the forced trend (signal) with respect to the trend associated with internal variability. The ratio of the signal to the spread of noise (SNR) was obtained by using the following procedure: first we determined the forced trend component by averaging the trend component of all the individual CMIP5 models. Then, we subtracted the forced trend component from the trend time series of each CMIP5 model to obtain an approximation of the unforced trend component, which can be attributed to internal and structural model variability. The spread of the unforced trend across individual models was measured using the standard deviation. The division between the forced trend value and the spread of the unforced trend quantifies the SNR (Gonzalez-Reviriego et al., 2015).

Finally, the forced response to climate change is analysed on the wheat-yield frequency distribution for the period 2070–2099 relative to the baseline period 1980–2014 of individual models and of one multi-model ensemble (MM-ensemble) with a box-whisker representation.

3 Results

3.1 Evaluation of GLAM-wheat simulations in Spain

Figure 2a shows the correlation coefficients (R) and the RMSE (in 10^3kg ha^{-1}) between GLAM-wheat and OBS-wheat to determine the correspondence in variability and mean biases respectively. Significant correlations, indicated by the dotted areas, were found in the

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

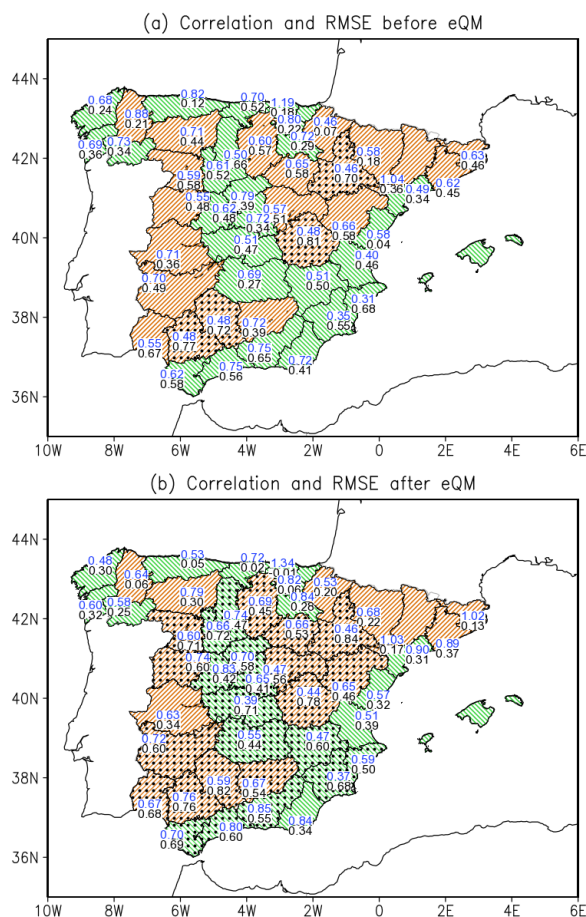


Figure 2: (a) Linear correlation (in black numbers), and Root Mean Square Error (10^3kg ha^{-1})(RMSE) (in blue numbers) of GLAM-wheat versus OBS-wheat. The dots indicate areas where the correlation is spatially significant according to the False Discovery Rate (FDR) metric. The brown and green patterns indicate the two cluster regions. (b) Same statistical metrics after recalibration using eQM

provinces of SV, CO, ZG and CU, which belong to region 2. The pattern significance was computed using the False Discovery Rate (FDR) tests (Wilks, 2016). We obtained a field significance of 13% at a 5% global significance level, which corresponds to the critical p-value of 0.016 due to the spatial correlation. However, after applying the eQM bias correction,

the adjustment of GLAM-wheat improved as Figure 2b shows with higher correlation coefficients, indicating a field significance of 57% at a 5% global significance level for the critical p-value of 0.028 in this case.

We examine the differences between GLAM-wheat and OBS-wheat in two regions that cluster the wheat yield of the provinces according

to similar wheat-yield variability. The effect of aggregation is illustrated in the Taylor diagram of supplementary Figure S2, which compares the correlation, root-mean-square difference and standard deviation of the GLAM-wheat results against the OBS-wheat, for the provinces and averaged wheat yield of both regions 1 and 2. Green (brown) points represent the metrics corresponding to region 1 (2). The closer the points to the reference (OBS), the better the performance. Therefore, according to the metrics represented in the Taylor diagram, the wheat averaged over region 1 and 2 improves the agreement between OBS-wheat and GLAM-wheat. The aggregated wheat-yield enhanced the signals and reduced errors with respect to individual provinces' wheat yield time series. The diagram also shows better model skill in region 2 than in region 1.

Figure 3 (a, b and c) represents in bars the GLAM-wheat versus the OBS-wheat averaged over Spain and regions 1 and 2. The corresponding correlation coefficients are 0.72, 0.63 and 0.76, which are statistically significant with a p-value < 0.05 . Region 2 shows better correspondence in variability. The solid black line gives the difference or bias between GLAM-wheat and OBS-wheat, which is compared with RMSE, represented in shaded light grey. Figure 3a shows a larger positive bias with GLAM-wheat $>$ OBS-wheat (lower negative bias with GLAM-wheat $<$ OBS-wheat), for years 1981, 1983, 2010 and 2014 (1999 and 2008). It is interesting to note that years 1981 and 1983 correspond to a warm phase or El Niño, while years 1999 and 2008 correspond to a cool phase or La Niña (Neelin, 2012). On the other hand, the year 2010 corresponds to a strong negative phase of the North Atlantic Oscillation (NAO). Some authors, such as Gimeno et al., (2002), Capa et al., (2016), Cantelaube et al., (2004), and Rodríguez-Puebla et al., (2007) point out examples of

ENSO (El Niño Southern Oscillation) and NAO impacting crops in Spain. Among others, Iizumi et al., (2014) studied impact of ENSO on the global yields. As a result, it appears

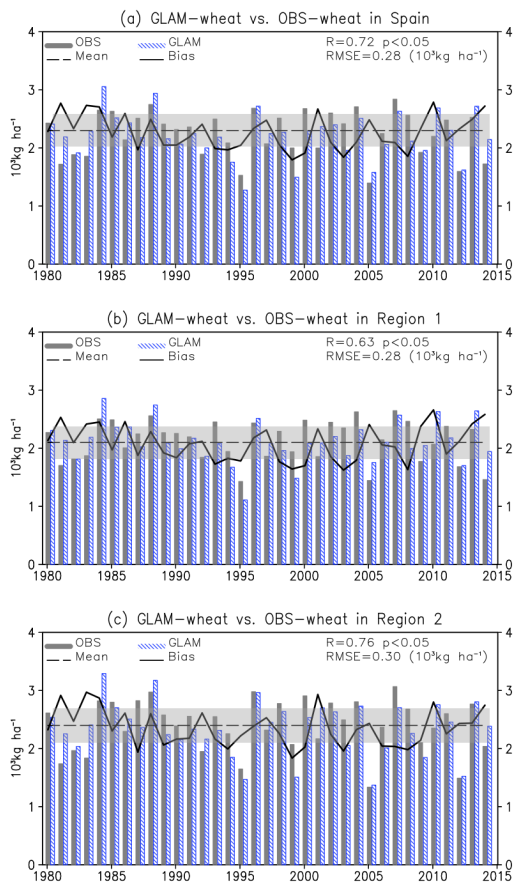


Figure 3: Time series of OBS-wheat (in dark grey) and GLAM-wheat (in blue hatching diagonal lines) for Spain (a), region 1 (b) and region 2 (c). Correspondence is quantified by the correlation (R) and RMSE. The solid black line represents the bias between GLAM-wheat vs. OBS-wheat. The dashed black line is the wheat-yield mean, and the light grey shade represents the RMSE

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

that some of the discrepancies between GLAM-wheat and OBS-wheat correspond to years of stronger teleconnection patterns. More details of this issue will be addressed in section 3.3.

3.2 Evaluation of simulated crop-climate relationships

We ask the following question: how well do GLAM-wheat yields respond to the climate drivers found in earlier studies (HB2016 and HB2017) in characterizing the OBS-wheat variability? This identification is important for wheat yield prediction.

We addressed this question using the equations indicated in section 2.5 for both cases using OBS-wheat and GLAM-wheat and for both regions 1 and 2. Tables 1 and 2 depict the parameters of the models. Cross-validation was applied to test how well the model estimates the predictions (Wilks, 2006). Leave-one-out cross-validation consisted of building a regression model, removing one year, and using this model to predict the wheat yield of the omitted year. This procedure was repeated for all the years. The predicted R-squared value derived for the fitted model before (R^2) and after (R^2_{CV}) cross-validation indicated that models based on SSRD better predict wheat-yield variability than the models based on SPI and DTR. The regression coefficients (a, b and c) indicated the effects of different modes of the climate variables (or PLS components) on wheat yield: negative in the case of SSRD. In the absence of water limitation the more radiation increases transpiration and biomass accumulation, however under water deficit higher solar radiation increases transpiration demand, thus enhancing water stress and lowering yields (Challinor et al., 2005b; Ramirez-Villegas et al., 2015). The SPI has a positive influence and DTR, a negative one. Relative consistency is found for OBS-wheat and GLAM-wheat.

According to the R-square values the empir-

ical model based on SSRD accounts for more wheat-variability than the model based on SPI and DTR, for both GLAM-wheat and OBS-wheat data, and both regions, 1 and 2.

In the case of OBS-wheat all the terms in the equations are significant. However in the case of GLAM-wheat, in autumn the terms SPI in both regions and SSRD in region 2 are not significant at the level 5%.

To illustrate the different responses of OBS-wheat and GLAM-wheat to the influence of climate variables, characterized by the PLS components (Table 1), we use scatterplot representation, which shows how OBS-wheat and GLAM-wheat respond to the individual PLS components of the climate variables of the equations in section 2.5.

Figure 4 (a, b and c) shows the wheat-yield sensitivity to the PLS components representative of solar radiation in autumn, winter and spring. Results for region 1 (2) are in green (brown). We deduce that as the magnitude of PLS_SSRD increases the wheat yield decreases. The seasonal effects of solar radiation are captured differently for GLAM-wheat than for OBS-wheat. For instance; in spring (Figure 4c) GLAM-wheat correlation in regions 1 and 2 (RG1 and RG2) (RG1= -0.86; RG2= -0.80) indicate stronger correlation with SSRD than OBS-wheat (RO) (RO= -0.80; RO= -0.76); in winter (Figure 4b) GLAM-wheat shows a weaker relationship (RG1= -0.69; RG2= -0.61) with solar radiation than OBS-wheat (RO1= -0.80; RO2=-0.88); in autumn (Figure 4a) GLAM-wheat (RG1= -0.81; RG2= -0.68) and OBS-wheat (RO1= -0.82; RO2= -0.77) show similar responses to SSRD in region 1, however, in region 2 they are weaker. These results show agreement with the different values of the parameters in the equations, a, b and c, as depicted in Table 1, with a less significant response of GLAM-wheat to SSRD in region 2 in the case of autumn (Table 1).

Table 1: Metrics of the linear model between observed (OBS-wheat) and simulated (GLAM-wheat) yield and PLS components of solar radiation (SSRD): R-squared before (R^2) ($p < 0.05$) and after (R^2_{CV}) cross-validation, and RMSE. Linear equation parameters (a, b, c) for regions 1 and 2, the significance level are given between bracket, characterized by the p-value (*no significant)

		R^2	R^2_{CV}	RMSE	a	b	c
GLAM-wheat	Region 1	0.86	0.85	0.14	-0.10 (0.014)	-0.11 ($2 \cdot 10^{-4}$)	-0.18 ($3 \cdot 10^{-5}$)
	Region 2	0.71	0.68	0.26	-0.041 (0.57)*	-0.13 (0.017)	-0.27 ($4.5 \cdot 10^{-4}$)
OBS-wheat	Region 1	0.85	0.84	0.14	-0.12 (0.003)	-0.14 ($8 \cdot 10^{-4}$)	-0.10 (0.008)
	Region 2	0.88	0.86	0.17	-0.10 (0.025)	-0.27 ($1 \cdot 10^{-5}$)	-0.10 (0.021)

Table 2: Metrics of the linear model between observed (OBS-wheat) and simulated (GLAM-wheat) yield and PLS components of the standardized precipitation index (SPI) and diurnal temperature range (DTR): R-squared before (R^2) ($p < 0.05$) and after (R^2_{CV}) cross-validation, and RMSE. Linear equation parameters (a, b, c) for regions 1 and 2, the significance level are given between bracket, characterized by the p-value (*no significant)

		R^2	R^2_{CV}	RMSE	a	b	c
GLAM-wheat	Region 1	0.66	0.61	0.22	0.025 (0.51)*	-0.17 ($1.1 \cdot 10^{-4}$)	0.23 ($1 \cdot 10^{-6}$)
	Region 2	0.71	0.67	0.26	0.08 (0.086)*	-0.23 ($1.8 \cdot 10^{-6}$)	0.29 ($1 \cdot 10^{-6}$)
OBS-wheat	Region 1	0.75	0.72	0.18	0.11 (0.0019)	-0.08 (0.012)	0.25 (0.000)
	Region 2	0.74	0.71	0.24	0.14 (0.0021)	-0.18 ($1.2 \cdot 10^{-4}$)	0.27 (0.000)

Figure 4 (d, e and f) shows the scatterplot of GLAM-wheat and OBS-wheat against SPI and DTR. Wheat yield increases as the magnitude of SPI increases and the magnitude of DTR decreases. The responses are different for GLAM-wheat and OBS-wheat. For instance: in spring (Figure 4f) the GLAM-wheat association with SPI ($RG1 = 0.65$; $RG2 = 0.65$) is lower than that with OBS-wheat ($RO1 = 0.76$; $RO2 = 0.67$); in autumn (Figure 4d), it was found that the GLAM-wheat response to SPI ($RG1 = 0.24$ ($p = 0.12$); $RG2 = 0.34$ ($p = 0.046$)) is practically insignificant and lower than OBS-wheat ($RO1 = 0.46$; $RO2 = 0.47$); however, in winter (Figure 4e) GLAM-wheat shows larger responses to DTR ($RG1 = -0.46$; $RG2 = -0.49$) than OBS-wheat ($RO1 = -0.28$ ($p = 0.099$); $RO2 = -0.45$).

The findings conclude that: in general, GLAM-wheat outputs are able to capture the seasonal climate variability, with higher (lower) response to SSRD (SPI) in spring; low (high) response to SSRD (DTR) in winter; and practically insignificant response to SPI and SSRD in region 2 in autumn. These comparisons provide information about the suitability of GLAM-wheat to represent their seasonal climate effects with advantages with respect to empirical models, which have some limitations for prediction purpose due to stationary characteristics of the equation parameters.

3.3 Evaluation of simulation crop-teleconnection relationships

As noted in section 3.1, some differences between GLAM-wheat and OBS-wheat (Figure

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

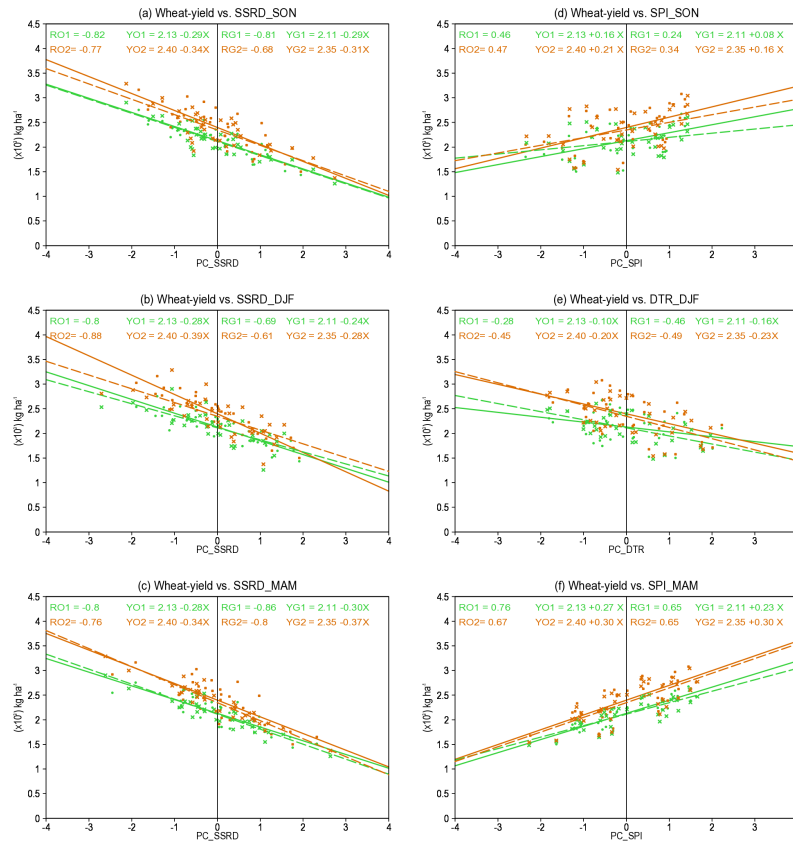


Figure 4: Scatterplot representations to show the response of the wheat yield to different climate drivers or PLS component. Solar radiation (SSRD) (a, b and c). Standardized Precipitation Index (SPI) (d and f). Diurnal temperature range (DTR) (e). Region 1 in green and region 2 in brown. RO1(2) gives the correlation coefficient between OBS-wheat and PLS_SSRD and RG1(2) shows the same metric but for the GLAM-wheat; YO1(2) and YG1(2) are the regression equations for the OBS-wheat and GLAM-wheat, respectively; X represents the PLS components. The thick line and dot characterize the adjustment and points in the case of OBS-wheat while the dash line and crosses are the same representations but for the GLAM-wheat

3a) seem to be associated with effects of El Niño events on wheat yields. To support this idea we assess the impacts of ENSO on OBS-wheat and GLAM-wheat in Spain following Izumi et al., (2014) on different yields. The impacts are determined by obtaining composite maps of wheat yield (OBS and GLAM) for years of ENSO events that occurred through

the period 1980 to 2014. Specifically, very strong (1982 and 1997) and moderate (1986, 1992 and 2009) El Niño, and strong (1988) and moderate (1998, 2000, 2007 and 2011) La Niña (<http://ggweather.com/enso/oni.htm>). The composite maps are performed with 1000 samples using the bootstrap with replacement procedure.

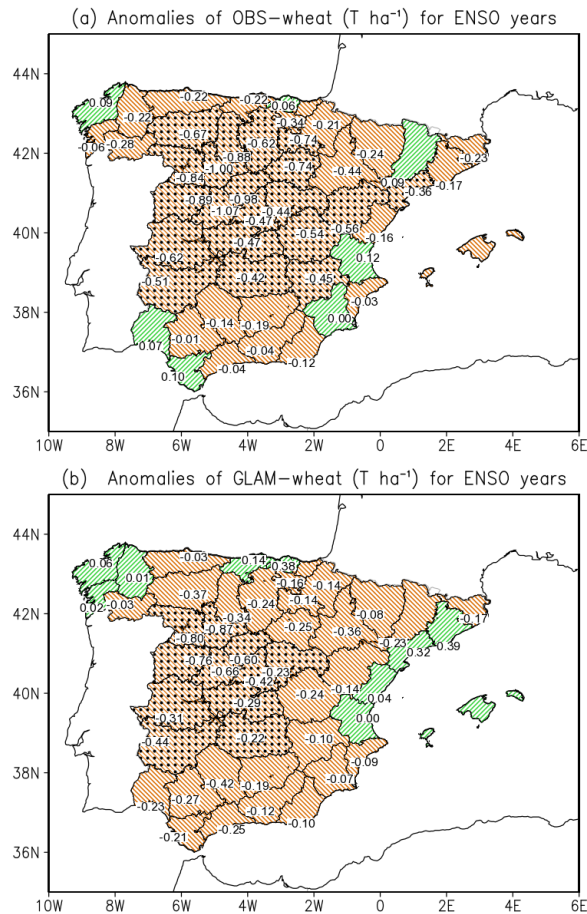


Figure 5: Composite maps of wheat yield for ENSO years: (a) using OBS-wheat; (b) using GLAM-wheat. The brown (green) pattern indicates negative (positive) anomalies. The dots reflects the provinces where differences are significant in the confidence interval >95% (or significant level $p < 0.05$) based on the 2-sided Student's t-test for the differences

Both composite maps of OBS-wheat and GLAM-wheat (Figure 5a, b) illustrate significant negative wheat yield anomalies, with larger amplitudes in the case of OBS-wheat. The significance of the patterns is 41% in case of OBS-wheat and 20% in case of GLAM-wheat. These results tell us about the association between wheat anomalies and ENSO

events and also that GLAM-wheat is not able to reproduce the intensity of wheat variability associated with ENSO events as OBS-wheat can for this period.

The ENSO is characterized by warm (cold) SST anomalies over equatorial Pacific. During warm phase enhanced evaporation moistens the atmosphere and intensifying convec-

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

tion leading to an increase of the global mean temperature (Trenberth et al., 2002). Pacific ENSO signals are communicated to the Atlantic via alteration of the tropical Walker and Hadley Cells (Mayer et al., 2016). These changes modifies storm track activity, subtropical Jet (Ding et al., 2017) and Northern Hemisphere extra-tropical circulation anomalies (Deser, 2017), which cause temperature and precipitation anomalies over the globe, and particularly in Spain (Frias et al., 2010; Palmeiro et al., 2017), through ENSO teleconnections.

Therefore, the effects of ENSO events on wheat yields can be explained because the ENSO induces anomalies in the climate variables that affect wheat yield. The SSRD, SPI and DTR responses to the ENSO are shown in composite maps for the same ENSO events considered to obtain the composite maps of wheat yields (supplementary Figure S3). It is interesting to highlight that El Niño years cause low SPI or drier conditions, and higher solar radiation in Spain in spring. A key question that requires further investigation is why GLAM-wheat fails to respond to ENSO?. Crop yields are vulnerable to extreme weather (Lesk et al., 2016; Lobell et al., 2012) and extreme events are associated with teleconnection indices as reported by Casanueva et al., 2014. GLAM-wheat has been showed weak association to ENSO, therefore, GLAM-wheat may not capture the intensity effects of extreme events as seen in OBS-wheat and in the empirical model based on solar radiation (EMP_SSRD-wheat) (HB2017). Hence, we suggest combining GLAM-wheat and EMP_SSRD-wheat to characterize wheat yield variability because this combination complement the influence of mean state of climate drivers and their extremes represented indirectly by effects of teleconnections indices.

3.4 Evaluation of the hybrid wheat yield simulation based on GLAM-wheat and EMP_SSRD-wheat

Process-based and empirical models are based on different assumptions, for example GLAM-wheat considers the day-to-day meteorological conditions but the empirical models consider the influence of the year-to-year climate variations. We have demonstrated in section 3.2 that both type of models are not independent because the responses to climate drivers show quite good agreement. Therefore, by averaging both models some differences could be complemented, for example to include effects of inter-annual variations on crops, and also to compensate prediction uncertainties. In this first approach we give the same weight to each model.

Figure 6 shows the skill of the hybrid model (hereafter GLAM_EMP-wheat) considering the correlation and RMSE with OBS-wheat. The correlation coefficients improve substantially in comparison to the ones obtained using GLAM-wheat (Figure 2b). However, the skill is similar with the ones obtained between EMP_SSRD-wheat and OBS-wheat (supplementary Figure S4). Spatially the performance of GLAM_EMP-wheat is better because the significance of the pattern correlation are 89% for GLAM_EMP-wheat, 83% for EMP_SSRD-wheat and 56% GLAM-wheat.

On the other hand, we evaluated GLAM_EMP-wheat temporally over Spain and the two regions in Figure 7 a, b, c. As expected, the agreements improve compared to those obtained between GLAM-wheat and OBS-wheat (Figure 3) due to the contribution of EMP_SSR-wheat, which provides better adjustment (supplementary Figure S5). Despite the better performance of EMP_SSRD-wheat over averaged regions and over all Spain, we consider the use of the

hybrid model to project wheat yield in studies of climate change (see Section 3.5) because the combination includes the advantages of process-based models for predicting future yield changes and the representativeness of large-scale patterns such as ENSO events given by the empirical model.

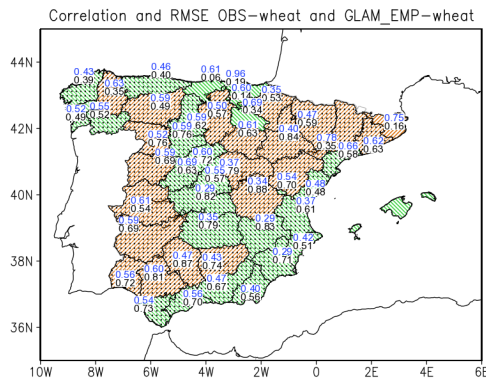


Figure 6: As Figure 2b but for GLAM_EMP-wheat

3.5 Wheat-yield changes combining wheat and CMIP5 models

The focus here is to compare different wheat simulations (GLAM_EMP-wheat, GLAM-wheat, EMP_SSRD-wheat and EMP_DTR_SPI-wheat) to determine the potential impacts of climate change on wheat yield in Spain.

GLAM-wheat is run with one realization of the daily data of SSRD, TX, TN and RR from each of nine CMIP5 experiments (Table S2). The use of multiple models should contribute to attaining confidence in the projections of the wheat yield responses to the forcing changes because climate models have a variety of errors (Flato et al., 2013).

The projections based on the empirical models are explained in earlier work (HB2016 and HB2017), however results are not the




Figure 7: As figure 3 but for GLAM_EMP-wheat

same because in earlier studies the eQM post-processing was not applied. Here we compare the projections after fitting projections to the observation-based data by using eQM. GLAM_EMP-wheat projections are obtained by averaging results from GLAM-wheat and EMP_SSRD-wheat and show results for all over Spain because they are more reliable for larger spatial averages.

We quantified the trend with Sen's estimator, gauging their significance with the Mann-

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

Kendall Z test (when Z tests higher than |2|). Table 3 depicts the results for the 21st century, giving changes in 10^3kg ha^{-1} in 100 years. Whilst different models produce different values, most projected a wheat-yield decrease. The largest decrease is given by the CNRM-CM5 model. The MM-ENSEMBLE shows a relative reduction in mean wheat yield of about 42% using GLAM-wheat, 25% using GLAM_EMP-wheat, and 13% (8%) in cases of EMP_SSRD-wheat (EMP_DTR_SPI). The causes of divergent projections may arise because of errors in the input of CMIP5 data (Watson et al., 2015). The noise is a problem for predictive purposes and the more noise the greater the uncertainty. Despite the difficulties in measuring the uncertainty of projections (Challinor et al., 2013; Vermeulen et al., 2013; Maiorano, 2017), we attempt to measure uncertainty for the trend component of the wheat-yield projections (Wesselink et al., 2015) by computing the signal-to-noise ratio (SNR) corresponding to the trend. Table 3 shows the ratio of the external forcing (signal) to the spread of unforced or internal variability or SNR of different types of models (GLAM-wheat, EMP_SSRD-wheat, EMP_DTR_SPI-wheat and GLAM_EMP-wheat) for the 21st century projections. Absolute values of SNR higher than 1 mean that forcing signal emerges with respect to the noise. All the type projections give SNR greater than 1. More robust signal of trend changes corresponds to GLAM-wheat (-3.8) and the hybrid model GLAM_EMP-wheat (-2.9), with lower SNR values were obtained for the two empirical models. GLAM_EMP-wheat gives smaller changes (-25%) than GLAM-wheat (-42%) (Table 3), and it has benefits of accounting for effects of climate drivers and teleconnection indices.

To visualize the changes Figures 8a and b show wheat-yield outputs in Spain using

GLAM-wheat and GLAM_EMP-wheat, and Figures 8c and 8d show the trend time series extracted from each model and the averaged trend extracted from the multi-model (MM-ENSEMBLE) by applying EEMD. Figure 9a and b compares the wheat-yield frequency distribution in the future period 2070–2099 to the baseline period 1980–2014 for the GLAM-wheat and GLAM_EMP-wheat corresponding to individual models and the multi-model ensemble with the box-whisker representation. We note similarity among the models for the period 1980–2014 because of the eQM adjustment applied to correct wheat distribution biases of the simulations with respect to OBS-wheat. These figures show noticeable wheat changes to decrease in the future climate.

4 Summary and discussion

In this study, we have evaluated the ability of GLAM-wheat to represent inter-annual variability of observed OBS-wheat. We found that the GLAM-wheat is able to accurately simulate wheat yield over larger areas in Spain (e.g. regions 1 and 2). These finding may have interesting practical applications - for example to integrate seasonal climate prediction (Vitart et al., 2017) with crop modelling, to provide indicators of agriculture productivity based on climate, and to support planning measures.

We explored some deficiencies of GLAM-wheat by considering the wheat responses to the PLS components that account for the effects of climate drivers, such as surface solar radiation, drought and diurnal temperature range. To this end we implemented the PLS regression approach applied to GLAM-wheat simulated yields with the climate variables. GLAM-wheat and OBS-wheat show similar sensitivities to SPI in spring. The effect of SPI is positive and strongest during the maturity phase (in spring), but a significant

Table 3: Wheat yield changes (10^3 kg/100yrs) in the 21st century for Spain using Sen’s estimator (SEN) and significance of the trend using the Man-Kendall (Z) test for individual models and multi-model (MM) ENSEMBLE. The relative change and signal-to-noise ratio (SNR) of the MM-ENSEMBLE

Model	GLAM		GLAM_EMP		EMP_SSRD		EMP_DTR_SPI	
	SEN	Z	SEN	Z	SEN	Z	SEN	Z
CCSM4	-1.0	-6.9	-0.5	-5.1	-0.06	-1.1	-0.4	-1.8
CMCC-CESM	-0.3	-4.1	-0.2	-1.9	0.06	0.6	-0.3	-3.9
CNRM-CM5	-1.4	-6.9	-1.0	-8.4	-0.6	-3.4	-0.1	-1.0
GFDL-ESM2M	-1.0	-7.9	-0.7	-5.6	-0.2	-2.2	-0.04	-0.2
HadGEM2-CC	-0.9	-5.5	-0.7	-6.4	-0.3	-2.4	-0.04	-0.02
HadGEM2-ES	-1.0	-5.0	-0.7	-5.5	-0.4	-3.4	-0.3	-1.5
MIROC5	-0.9	-13.6	-0.6	-5.6	-0.2	-1.2	-0.04	-0.4
MPI-ESM-MR	-0.7	-6.3	-0.5	-4.7	-0.3	-1.4	-0.1	-1.3
NorESM1-M	-0.9	-3.4	-0.7	-5.2	-0.4	-2.5	-0.04	-0.8
MM-ENSEMBLE	-1.0	-11.0	-0.67	-9.8	-0.3	-4.5	-0.2	-2.5
Relative change	-42%		-25%		-13%		-8%	
SNR	-3.8		-2.9		-1.4		-1.1	




Figure 8: Wheat-yield projections from different CMIP5 models. (a) Using GLAM-wheat; (b) using GLAM_EMP-wheat; (c) Filtered trend of wheat yield for GLAM-wheat projections; (d) Filtered trend of wheat yield for GLAM_EMP-wheat projections

positive effect was also found during sowing phase (in autumn). However, GLAM-wheat sensitivity to SPI in autumn is insignificant. These results are in agreement with Ben-Ari

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

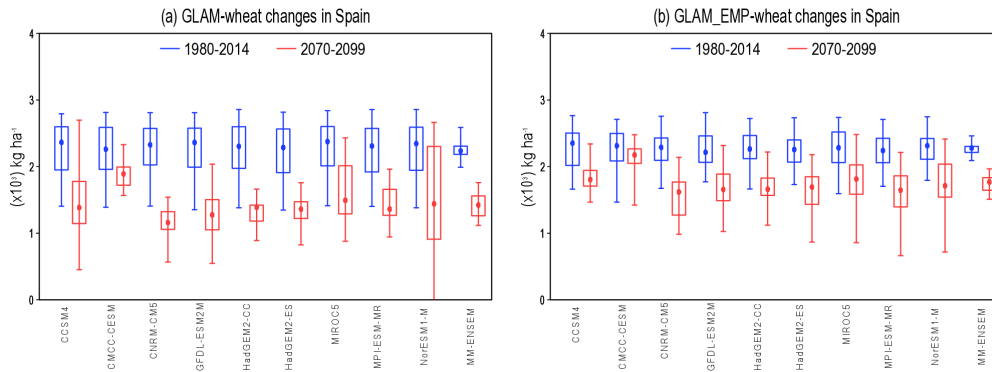


Figure 9: Box-whisker representation of wheat-yield distribution using GLAM-wheat and GLAM_EMP-wheat for individual CMIP5 models in two periods. The median is the dot within the box, the 25th and 75th percentiles are the top and bottom ends of the boxes

et al., (2016) and Iglesias et al., (2012), who found drought as an indicator to predict extreme wheat-yield loss in Spain, and with the results of Potgieter et al., (2016) in Australia about the effects of dry and wet conditions on wheat trends, and also with Wang et al., (2016) who studied relationships between winter wheat in Northern China and drought indices.

GLAM-wheat is more sensitive to DTR in winter than OBS-wheat. DTR affects it negatively due to the relationships between temperature and crop development that decline with high maximum and low minimum temperatures (Lobell and Ortiz-Monasterio, 2007; Olesen et al., 2012); low minimum temperature causes damage due to frost and root growth.

We point out the robustness of the response of both GLAM-wheat and OBS-wheat yield to radiative variability (SSRD) and changes. The effects of SSRD on wheat yield in Spain are different from the ones obtained in China (Chen et al., 2013; Xiao et al., 2016), in Denmark (Kristensen et al., 2011) and in the UK (Landa et al., 2000). This can be explained by the water stress over the regions in Spain. Ac-

ording to our previous study (HB2017), SSRD accounts for most of the effects of rainfall and daily temperature range since more solar radiation implies less cloudiness, less precipitation, lower minimum temperatures, and higher maximum temperatures. SSRD accounts also for teleconnection influences, which agree with Awoyea et al., (2017), Ceglár et al., (2017) and HB2017 about the utility of large-scale climate predictors for crop modelling.

We observed greater differences between GLAM-wheat and OBS-wheat for ENSO years. These observational findings indicate weaker response to ENSO in cases of GLAM-wheat than of OBS-wheat- i.e. that the observations show a relationship with ENSO that GLAM does not show as strongly. In general, negative wheat yield anomalies correspond to El Niño, however, most provinces show larger amplitudes in the case of OBS-wheat than GLAM-wheat, and also the pattern significance is greater in the case of OBS-wheat (41% vs. 20%). Regarding these finding further investigations are needed to answer why GLAM-wheat fails to respond to ENSO. Iizumi et al., (2014) reported negative (positive) in-

significant impacts of El Niño (La Niña) on wheat yield in Spain. Some possible reasons for these differences are that we used different source for the wheat yield data, and we considered longer period of El Niño/La Niña.

Our results pointed to combining the process-based and empirical wheat simulations (GLAM_EMP-wheat) to incorporate more climate impacts on wheat yields and to compensate for limitations and advantages of each type of model, because EMP_SSRD-wheat and GLAM-wheat combination complement the influence of mean state of climate drivers and their extremes represented indirectly by effects of teleconnections indices. We found that GLAM_EMP-wheat accounts for more variance (83%) than GLAM-wheat (52%), but lower variance than the empirical GLAM_SSRD-wheat (90%) in the case of wheat yield averaged over all of Spain. GLAM_SSRD-wheat accounts for more OBS-wheat variance than the model proposed by Ceglar et al. 2017 based in a combination of Northern Atlantic teleconnection indices, which accounts for less than 50% of observed variance in the case of wheat yield prediction in Spain. For the individual provinces GLAM_EMP-wheat simulations give greater pattern significance (89%) than GLAM-wheat (56%) and EMP_SSRD-wheat (83%).

All the projections show a decrease in wheat yield, of about 42% (GLAM-wheat) and 25% (GLAM_EMP-wheat) across the 21st century for the MM-ensemble over all Spain. The less negative yield impact of GLAM_EMP-wheat is unclear. It can be attributed to modulation of interannual and decadal variability associated with teleconnections or because in less humid sites are less sensitive to warming because of greater evaporative cooling (Lobell and Asseng, 2017). Estes et al., 2013, compared empirical and process-based model projections of climate change impacts to maize and spring

wheat finding losses (gains) in case of empirical (process-based) models. The reduction in wheat yield can be interpreted as a consequence warming and drying over southern Europe (Kröner et al., 2017). The supplementary Figure S6 shows the projected changes of climate drivers of wheat yield, such as SSRD in SON, DJF and MAM, and the supplementary Figure S7 shows the projected changes of SPI in SON and MAM and for DTR in DJF. These time series correspond to the MM-ENSEMBLE. We note a tendency to increase in the case of SSRD, with a greater increase in spring and autumn than in winter. This increased trend of SSRD agrees with the brightening in Spain reported by Sanchez-Lorenzo et al., (2013) and Wild (2016). We found a tendency to increase in the case of DTR in winter, due to higher maximum temperatures (Brunet et al., 2007; del Rio et al., 2012; El Kenawy et al., 2011; Rodriguez-Puebla et al., 2010), and we observed a tendency to decrease in the case of SPI in spring, which agrees with studies on observed and projections of rainfall over Spain (Esteban-Parra et al., 1998; Nieto and Rodriguez-Puebla, 2006).

There are large uncertainties in projections of yields due to differences in crop models (Asseng et al., 2013; Garrido et al., 2011; Iglesias et al., 2010; Landau et al., 1998; Lawless et al., 2008; Ruiz-Ramos and Minguéz, 2010; Tebaldi and Lobell, 2008; Tebaldi et al., 2005; Vermeulen et al., 2013) and climate models (Collins et al., 2012; IPCC, 2013; Xie et al., 2015). For example, Macadam et al., (2016) found great uncertainty due to the rainfall provided by the Regional Climate Model with an APSIM crop model in simulating wheat in Australia. However, wheat yield responses to climate change are more robust in the GLAM-wheat and GLAM_EMP-wheat models than the individual empirical models because the signal-to-noise ratio (SNR) leads to higher ab-

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

solute values.

We have made an effort to better understand and quantify projections of wheat yield in Spain. Further research needs to deal with the problem of managing risk to protect the crops from environmental problems such as the spread of infection (Bhattacharya, 2017), which can be caused by the warmer autumns and milder winters expected with climate change.

Acknowledgments

We acknowledge the Climate Impacts Group of the School of Earth and Environment of the University of Leeds for giving us the opportunity to use the winter wheat version of GLAM. We also acknowledge the data providers: ECMWF for ERA-interim reanalysis; E-OBS dataset from the EU-FP6 project ENSEMBLES; the U.S. Department of Energy’s Program for Climate Model Diagnosis and Intercomparison provided CMIP5 data; Spanish Agriculture, Food and Environment (MAGRAMA) for crop data. Thanks also to the developers of GrADS, CDO, NCL, MATLAB and R software. This work was supported by the Ministry of Economy and Competitiveness of Spain under National project (CGL-2011-23209/CLI) and fellowship BES-2012-054447 granted to S. Hernandez-Barrera.

References

- Asseng S et al. (2013) Uncertainty in simulating wheat yields under climate change. *Nature Climate Change*, 3(9): 827-832.
- Asseng S, Ewert F, Martre P, Rötter RP, Lobell DB, Cammarano D, Kimball BA, Ottman MJ, Wall GW, White JW, Reynolds MP, Alderman PD, Prasad PVV, Aggarwal PK, Anothai J, Basso B, Biernath C, Challinor AJ, de Sanctis G, Doltra J, Fereres E, Garcia-Vila M, Gayler S, Hoogenboom G, Hunt LA, Izaurralde RC, Jabloun M, Jones CD, Kersebaum KC, Koehler AK, Müller C, Naresh Kumar S, Nendel C, O’ Leary G, Olesen JE, Palosuo T, Priesack E, Eyshi Rezaei E, Ruane AC, Semenov MA, Shcherbak I, Stöckle C, Stratonovitch P, Streck T, Supit I, Tao F, Thorburn PJ, Waha K, Wang E, Wallach D, Wolf J, Zhao Z, Zhu Y (2015) Rising temperatures reduce global wheat production. *Nat. Clim. Change* 5(2): 143–147, doi: 10.1038/NCLIMATE2470.
- Auffhammer M, Schlenker W (2014) Empirical studies on agricultural impacts and adaptation. *Energy Economics*, 46: 555-561.
- Awoyea OHR, Pollinger F, Agbossou EK, Paetha H (2017) Dynamical-statistical projections of the climate change impact on agricultural production in Benin by means of a cross-validated linear model combined with Bayesian statistics. *Agricultural and Forest Meteorology*, 234-235, 80-94.
- Bhattacharya S (2017) Wheat rust back in Europe. *Nature*, 542,145-146.
- Ben-Ari T et al. (2016) Identifying indicators for extreme wheat and maize yield losses. *Agricultural and Forest Meteorology*, 220: 130-140.
- Brunet M et al. (2007) Temporal and spatial temperature variability and change over Spain during 1850-2005. *Journal of Geophysical Research-Atmospheres*, 112(D12).
- Cantelaube P, Terres JM, Doblas-Reyes FJ (2004) Influence of climate variability on European agriculture – analysis of winter wheat production. *Clim. Res.* 27(2): 135–144.
- Capa-Morocho M, Rodriguez-Fonseca B, Ruiz-Ramos M (2016) El Nino influence on potential maize yield in Iberian Peninsula. *Int. J. Climatol.* 36(3): 1313–1330, doi: 10.1002/joc.4426.
- Casanueva A, Rodriguez-Puebla C, Frias MD, Gonzalez-Reviriego N (2014) Variability of extreme precipitation over Europe and its relationships with teleconnection patterns, *Hydrol. Earth Syst. Sci.*, 18, 709-725, doi:10.5194/hess-18-709-2014.
- Casanueva A, Kotlarski S, Herrera S, Fernández J, Gutiérrez JM, Boberg F, Colette A, Christensen OB, Goergen K, Jacob D, Keuler K, Nikulin G, Teichmann C, Vautard R (2016) Daily precipitation statistics in a EURO-CORDEX RCM ensemble: added value of raw and bias-corrected high-resolution simulations. *Climate Dynamics*, 47(3-4): 719-737.
- Ceglár A, Turco M, Toreti A, Doblas-Reyes FJ (2017) Linking crop yield anomalies to large-scale atmospheric circulation in Europe. *Agricultural and Forest Meteorology* 240-241, 35-45. doi: 10.1016/j.agrformet.2017.03.019.

- Challinor AJ, Simelton ES, Fraser EDG, Hemming D, Collins M (2010) Increased crop failure due to climate change: assessing adaptation options using models and socio-economic data for wheat in China. *Environmental Research Letters*, 5(3).
- Challinor A, Martre P, Asseng S, Thornton P, Ewert F, (2014a) COMMENTARY: Making the most of climate impacts ensembles. *Nature Climate Change*, 4(2): 77-80.
- Challinor AJ, Ewert F, Arnold S, Simelton E, Fraser E (2009) Crops and climate change: progress, trends, and challenges in simulating impacts and informing adaptation. *Journal of Experimental Botany*, 60(10): 2775-2789.
- Challinor AJ, Slingo JM, Wheeler TR, Doblaz-Reyes FJ (2005a) Probabilistic simulations of crop yield over western India using the DEMETER seasonal hindcast ensembles. *Tellus Series a-Dynamic Meteorology and Oceanography*, 57(3): 498-512.
- Challinor AJ, Smith MS, Thornton P (2013) Use of agro-climate ensembles for quantifying uncertainty and informing adaptation. *Agricultural and Forest Meteorology*, 170: 2-7.
- Challinor AJ et al. (2014b) A meta-analysis of crop yield under climate change and adaptation. *Nature Climate Change*, 4(4): 287-291.
- Challinor AJ, Wheeler TR, Craufurd PQ, Slingo JM (2005b) Simulation of the impact of high temperature stress on annual crop yields. *Agricultural and Forest Meteorology*, 135(1-4): 180-189.
- Challinor AJ, Wheeler TR, Craufurd PQ, Slingo JM, Grimes DIF (2004) Design and optimisation of a large-area process-based model for annual crops. *Agricultural and Forest Meteorology*, 124(1-2): 99-120.
- Challinor AJ, Koehler A-K, Ramirez-Villegas J, Whitfield S, Das B (2016) Current warming will reduce yields unless maize breeding and seed systems adapt immediately. *Nature Climate Change*, DOI: 10.1038/NCLIMATE3061
- Chen C, Greene AM, Robertson AW, Baethgen WE, Eamus D (2013) Scenario development for estimating potential climate change impacts on crop production in the North China Plain. *International Journal of Climatology*, 33(15): 3124-3140.
- Chen X, Wang M, Zhang Y, Feng Y, Wu Z, Huang NE (2013) Detecting signals from data with noise: theory and applications. *J. Atmos. Sci.* 70(5): 1489-1504, doi: 10.1175/jas-d-12-0213.1.
- Ciscar J, Soria A, Lavalle C, Raes F, Perry M, Nemry F, Demirel H, Rozsai M, Dosio A, Donatelli M, Srivastava A, Fumagalli D, Niemeyer S, Shrestha S, Ciaian P, Himics M, VanDoorslaer B, Barrios S, Ibanez N, Bianchi A, Dowling P, Camia A, Liberta G, San Miguel J, de Rigo D, Caudullo G, Barredo J, Paci D, Pycroft J, Saveyn B, VanRegemorter D, Revesz T, Vandyck T, Vrontisi Z, Baranzelli C, Vandecasteele I, BatistaSilva F, Ibarreta D (2014) Climate impacts in europe. the jrc peseta II project. Report (<http://www.jrc.ec.europa.eu>)
- Collins M et al. (2012) Quantifying future climate change. *Nature Climate Change*, 2(6): 403-409.
- Conradt T, Gornott C, Wechsung F (2016) Extending and improving regionalized winter wheat and silage maize yield regression models for Germany: Enhancing the predictive skill by panel definition through cluster analysis. *Agricultural and Forest Meteorology*, 216: 68-81.
- Dee DP et al. (2011) The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Quarterly Journal of the Royal Meteorological Society*, 137(656): 553-597.
- Déqué M (2007) Frequency of precipitation and temperature extremes over France in an anthropogenic scenario: Model results and statistical correction according to observed values. *Global and Planetary Change*, 57 (12), 1626, doi:10.1016/j.gloplacha.2006.11.030.
- del Rio S, Cano-Ortiz A, Herrero L, Penas A (2012) Recent trends in mean maximum and minimum air temperatures over Spain (1961-2006). *Theoretical and Applied Climatology*, 109(3-4): 605-626.
- Deser C, Terray L, Phillips AS (2016) Forced and Internal Components of Winter Air Temperature Trends over North America during the past 50 Years: Mechanisms and Implications. *Journal of Climate*, 29(6): 2237-2258.
- Eitzinger J et al. (2009) Adaptation of vulnerable regional agricultural systems in Europe to climate change - results from the ADAGIO project. *Advances in Science and Research*, 3: 133-135.
- El Kenawy A, Lopez-Moreno JI, Vicente-Serrano SM (2011) Recent trends in daily temperature extremes over northeastern Spain (1960-2006). *Natural Hazards and Earth System Sciences*, 11(9): 2583-2603.
- Esteban-Parra MJ, Rodrigo FS, Castro-Diez Y (1998) Spatial and temporal patterns of precipitation in Spain for the period 1880-1992. *International Journal of Climatology*, 18(14): 1557-1574.
- Ewert F et al. (2015) Crop modelling for integrated assessment of risk to food production from climate change. *Environmental Modelling & Software*, in press.
- Ewert F, Rounsevell M, Reginster I, Metzger M, Lee-mans R (2006) Technology development and cli-

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

- mate change as drivers of future agricultural land use. *Agriculture and Climate Beyond 2015: a New Perspective on Future Land Use Patterns*, 46: 33-51.
- Falloon P, Betts R (2010) Climate impacts on European agriculture and water management in the context of adaptation and mitigation-The importance of an integrated approach. *Science of the Total Environment*, 408(23): 5667-5687.
- Fang GH, Yang J, Chen YN, Zammit C (2015) Comparing bias correction methods in downscaling meteorological variables for a hydrologic impact study in an arid area in China. *Hydrology and Earth System Sciences*, 19(6): 2547-2559.
- Flato G et al. (2013) Evaluation of climate models. *Climate Change 2013: The Physical Science Basis*. T.F. Stocker et al. , Eds. Cambridge University Press, 741-866.
- Foley JA, Monfreda C, Ramankutty N, Zaks D. (2007) Our share of the planetary pie, *Proc. Natl. Acad. Sci.*, 104(31), 12,585–12,586, doi:10.1073/pnas.0705190104.
- Finger R (2010) Evidence of slowing yield growth - The example of Swiss cereal yields. *Food Policy*, 35(2): 175-182.
- Frias MD, Herrera S, Cofino AS, Gutierrez JM (2010) Assessing the Skill of Precipitation and Temperature Seasonal Forecasts in Spain: Windows of Opportunity Related to ENSO Events. *Journal of Climate*, 23(2): 209-220.
- Garrido A, Rey D, Ruiz-Ramos M, Minguez MI (2011) Climate change and crop adaptation in Spain: consistency of regional climate models. *Climate Research*, 49(3): 211-227.
- Garrigos J, Molina JM, Alarcon M, Chazarra J, Ruiz-Canales A, Martinez JJ (2017) Platform for the management of hydraulic chambers based on mobile devices and Bluetooth Low-Energy notes. *Agricultural Water Management*, 183, 169-176.
- Gervois S et al. (2008) Carbon and water balance of European croplands throughout the 20th century. *Global Biogeochemical Cycles*, 22(2).
- Gimeno L, Ribera P, Iglesias R, de la Torre L, Garcia R, Hernandez E (2002) Identification of empirical relationships between indices of ENSO and NAO and agricultural yields in Spain. *Clim. Res.* 21(2): 165–172, doi: 10.3354/cr021165.
- Gonzalez-Reviriego N, Rodriguez-Puebla C, Rodriguez-Fonseca B (2015) Evaluation of observed and simulated teleconnections over the Euro-Atlantic region on the basis of partial least squares regression. *Clim. Dyn.* 44(11–12): 2989–3014, doi: 10.1007/s00382-014-2367-2.
- Gornall J et al. (2010) Implications of climate change for agricultural productivity in the early twenty-first century. *Philosophical Transactions of the Royal Society B-Biological Sciences*, 365(1554): 2973-2989.
- Gornott C, Wechsung F (2016) Statistical regression models for assessing climate impacts on crop yields: a validation study for winter wheat and silage maize in Germany. *Agric. For. Meteorol.* 217: 89–100, doi: 10.1016/j.agrformet.2015.10.005.
- Guttman NB (1998) Comparing the Palmer Drought Index and the standardized precipitation index. *Journal of the American Water Resources Association*, 34(1): 113-121.
- Harris JM, Kennedy S (1999) Carrying capacity in agriculture: Global and regional issues, *Ecol. Econ.*, 29(3), 443–461.
- Hawkins E, Osborne TM, Ho CK, Challinor AJ (2013) Calibration and bias correction of climate projections for crop modelling: An idealised case study over Europe. *Agricultural and Forest Meteorology*, 170: 19-31.
- Haylock MR et al. (2008) A European daily high-resolution gridded data set of surface temperature and precipitation for 1950-2006. *Journal of Geophysical Research-Atmospheres*, 113(D20).
- Hernandez-Barrera S, Rodríguez-Puebla C, Challinor A (2016) Effects of diurnal temperature range and drought on wheat yield in Spain. *Theor Appl Climatol* Accepted. doi: 10.1007/s00704-016-1779-9.
- Hernandez-Barrera S, Rodríguez-Puebla C (2017) Wheat yield in Spain and associated solar radiation patterns. *International Journal of Climatology*, submitted.
- Huang NE et al. (1998) The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society a-Mathematical Physical and Engineering Sciences*, 454(1971): 903-995. JCLI-D-14-00006.1.
- Iglesias A, Quiroga S, Schlickerrieder J (2010) Climate change and agricultural adaptation: assessing management uncertainty for four crop types in Spain. *Climate Research*, 44(1): 83-94.
- Iglesias A, Garrote L, Quiroga S, Moneo M (2012) From climate change impacts to the development of adaptation strategies: challenges for agriculture in Europe. *Climatic Change*, 112:143–168, DOI: 10.1007/s10584-011-0344-x.
- Iizumi T, Luo JJ, Challinor AJ, Sakurai G, Yokozawa M, Sakuma H, Brown ME, Yamagata T (2014) Impacts of El Niño Southern oscillation on the

- global yields of major crops. *Nat. Commun.* 5(7): 3712, doi: 10.1038/ncomms4712.
- IPCC (2013) *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change.* Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1535 pp.
- IPCC (2014) *WGII AR5. Chapter 7 Food Security and Food Production Systems.* Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 82 pp.
- Jamieson PD et al. (2007) Reconciling alternative models of phenological development in winter wheat. *Field Crops Research*, 103(1): 36-41.
- Kendall M (1938) A New Measure of Rank Correlation. *Biometrika*, 30(1-2): 81-89.
- Kingston DG, Stagge JH, Tallaksen LM, Hannah DM (2015) European-Scale Drought: Understanding Connections between Atmospheric Circulation and Meteorological Drought Indices. *Journal of Climate*, 28(2): 505-516.
- Knutti R, Sedlacek J (2013) Robustness and uncertainties in the new CMIP5 climate model projections. *Nat. Clim. Change* 3(4): 369-373, doi: 10.1038/nclimate1716.
- Koehler AK, Challinor AJ, Hawkins E, Asseng S (2013) Influences of increasing temperature on Indian wheat: quantifying limits to predictability. *Environmental Research Letters*, 8(3).
- Kristensen K, Schelde K, Olesen JE (2011) Winter wheat yield response to climate variability in Denmark. *Journal of Agricultural Science*, 149: 33-47.
- Kröner N, Kotlarski S, Fischer E, Lüthi D, Zubler E, Schär C (2017) Separating climate change signals into thermodynamic, lapse-rate and circulation effects: theory and application to the European summer climate. *Clim Dyn* (2017) 48: 3425. doi:10.1007/s00382-016-3276-3.
- Landau S et al. (1998) Testing winter wheat simulation models' predictions against observed UK grain yields. *Agricultural and Forest Meteorology*, 89(2): 85-99.
- Landau S et al. (2000) A parsimonious, multiple-regression model of wheat yield response to environment. *Agricultural and Forest Meteorology*, 101(2-3): 151-166.
- Lawless C, Semenov MA, Jamieson PD (2008) Quantifying the effect of uncertainty in soil moisture characteristics on plant growth using a crop simulation model. *Field Crops Research*, 106(2): 138-147.
- Lesk C, Rowhani P, Ramankutty N (2016) Influence of extreme weather disasters on global crop production. *Nature*, 529(7584): 84-+.
- Li S (2008) Investigating the impacts of climate change on wheat in China. PhD thesis, University of Reading, Reading, UK.
- Lloyd-Hughes B, Saunders MA (2002) A drought climatology for Europe. *International Journal of Climatology*, 22(13): 1571-1592.
- Lobell DB, Asner GP (2003) Climate and management contributions to recent trends in US agricultural yields. *Science*, 299(5609): 1032-1032.
- Lobell DB, Asseng S (2017) Comparing estimates of climate change impacts from process-based and statistical crop models. *Environmental Research Letters* 12(1):015001.
- Lobell DB, Burke MB (2010) On the use of statistical models to predict crop yield responses to climate change. *Agricultural and Forest Meteorology*, 150(11): 1443-1452.
- Lobell DB et al. (2008) Prioritizing climate change adaptation needs for food security in 2030. *Science*, 319(5863): 607-610.
- Lobell DB, Field CB (2007) Global scale climate - crop yield relationships and the impacts of recent warming. *Environmental Research Letters*, 2(1).
- Lobell DB, Gourdji SM (2012) The Influence of Climate Change on Global Crop Productivity. *Plant Physiology*, 160(4): 1686-1697.
- Lobell DB, Ortiz-Monasterio JI (2007) Impacts of day versus night temperatures on spring wheat yields: A comparison of empirical and CERES model predictions in three locations. *Agronomy Journal*, 99(2): 469-477.
- Lobell DB, Ortiz-Monasterio JI, Falcon WP (2007) Yield uncertainty at the field scale evaluated with multi-year satellite data. *Agricultural Systems*, 92(1-3): 76-90.
- Lobell DB, Schlenker W, Costa-Roberts J (2011a) Climate Trends and Global Crop Production Since 1980. *Science*, 333(6042): 616-620.
- Lobell DB, Torney A, Field CB (2011b) Climate extremes in California agriculture. *Climatic Change*, 109: 355-363.
- Lobell DB, Sibley A, Ortiz-Monasterio JI (2012) Extreme heat effects on wheat senescence in India. *Nature Clim. Change* 2, 186-189.
- Long SP, Ainsworth EA, Leakey ADB, Nosberger J, Ort DR (2006) Food for thought: Lower-than-expected crop yield stimulation with rising CO2 concentrations. *Science*, 312(5782): 1918-1921.
- Macadam I, Argüeso D, Evans JP, Liu, deli and Pitman AJ (2016) The effect of bias correction and climate model resolution on wheat simulations forced with

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

- a regional climate model ensemble. *International Journal of Climatology*, on line.
- MAGRAMA. Spanish Agriculture, Food and Environment Department. <http://www.magrama.gob.es/es/estadistica/temas/estadisticas-agrarias/agricultura/avances-superficies-producciones-agricolas/>.
- Maiorano A et al. (2017) Crop model improvement reduces the uncertainty of the response to temperature of multi-model ensembles. *Field Crops Res.*, 202, 5-20, doi:10.1016/j.fcr.2016.05.001.
- Makowski D et al. (2015) A statistical analysis of three ensembles of crop model responses to temperature and CO₂ concentration. *Agricultural and Forest Meteorology*, 214: 483-493.
- Mayer M, Fasullo JT, Trenberth KE, Haimberger L (2016) ENSO-driven energy budget perturbations in observations and CMIP models. *Climate Dynamics*, 47(12): 4009-4029.
- Mearns LO (2003) Issues in the impacts of climate variability and change on agriculture -applications to the southeastern United States. *Clim. Change* 60(1-2): 1-6.
- Medina Martín F (2015) Impactos, vulnerabilidad y adaptación al cambio climático en el sector agrario: Aproximación al conocimiento y prácticas de gestión en España. Oficina Española de Cambio Climático. Ministerio de Agricultura, Alimentación y Medio Ambiente, Madrid.
- Moore FC, Lobell DB (2014) Adaptation potential of European agriculture in response to climate change. *Nature Climate Change*, 4(7): 610-614.
- Moore FC, Lobell DB (2015) The fingerprint of climate trends on European crop yields. *Proceedings of the National Academy of Sciences of the United States of America*, 112(9): 2670-2675.
- Moriondo M et al. (2010) Impact and adaptation opportunities for European agriculture in response to climatic change and variability. *Mitigation and Adaptation Strategies for Global Change*, 15(7): 657-679.
- Neelin JD (2012) *Climate Change and Climate Modeling*. Cambridge University Press. ISBN-13:978-0521602433.
- Nieto S, Rodríguez-Puebla C (2006) Comparison of precipitation from observed data and general circulation models over the Iberian Peninsula. *Journal of Climate*, 19(17): 4254-4275.
- Nicklin K (2013) Seasonal crop yield forecasting in semi-arid West Africa PhD thesis, University of Reading, Reading, UK.
- Olesen JE et al. (2012) Changes in time of sowing, flowering and maturity of cereals in Europe under climate change. *Food Additives and Contaminants Part a-Chemistry Analysis Control Exposure & Risk Assessment*, 29(10): 1527-1542.
- Olesen JE, Jensen T, Petersen J (2000) Sensitivity of field-scale winter wheat production in Denmark to climate variability and climate change. *Climate Research*, 15(3): 221-238.
- Palmeiro FM, Iza M, Barriopedro D, Calvo N, García-Herrera R (2017) The complex behavior of El Niño winter 2015-2016. *Geophysical Research Letters*, 44(6): 2902-2910.
- Palosuo T et al. (2011) Simulation of winter wheat yield and its variability in different climates of Europe: A comparison of eight crop growth models. *European Journal of Agronomy*, 35(3): 103-114.
- Parry M, Rosenzweig C, Livermore M (2005) Climate change, and risk global food supply of hunger. *Philosophical Transactions of the Royal Society B-Biological Sciences*, 360(1463): 2125-2138.
- Porter JR, Semenov MA (1999) Climate variability and crop yields in Europe. *Nature*, 400(6746): 724-724.
- Porter JR, Semenov MA (2005) Crop responses to climatic variation. *Philosophical Transactions of the Royal Society B-Biological Sciences*, 360(1463): 2021-2035.
- Potgieter AB et al. (2016) Yield trends under varying environmental conditions for sorghum and wheat across Australia. *Agricultural and Forest Meteorology*, 228: 276-285.
- Ramírez-Villegas J, Challinor A (2012) Assessing relevant climate data for agricultural applications. *Agricultural and Forest Meteorology*, 161: 26-45.
- Ramírez-Villegas J, Challinor AJ (2016) Towards a genotypic adaptation strategy for Indian groundnut cultivation using an ensemble of crop simulations. *Climatic Change*, 138(1-2): 223-238.
- Ramírez-Villegas J, Challinor AJ, Thornton PK, Jarvis A (2013) Implications of regional improvement in global climate models for agricultural impact research. *Environmental Research Letters*, 8(2).
- Ramírez-Villegas J, Koehler AC, Challinor AJ (2015) Assessing uncertainty and complexity in regional-scale crop model simulations. *European Journal of Agronomy*, (in press).
- Rodríguez-Puebla C, Ayuso SM, Frias MD, García-Casado LA (2007) Effects of climate variation on winter cereal production in Spain. *Clim. Res.* 34(3): 223-232.
- Rodríguez-Puebla C, Encinas AH, García-Casado LA, Nieto S (2010) Trends in warm days and cold nights over the Iberian Peninsula: relationships to large-scale variables. *Climatic Change*, 100(3-

- 4): 667-684.
- Rosenzweig C et al. (2013) The Agricultural Model Intercomparison and Improvement Project (AgMIP): Protocols and pilot studies. *Agricultural and Forest Meteorology*, 170: 166-182.
- Rosenzweig C, Parry ML (1994) Potential impact of climate-change on world food-supply. *Nature*, 367(6459): 133-138.
- Rotter RP, Carter TR, Olesen JE, Porter JR (2011) Crop-climate models need an overhaul. *Nature Climate Change*, 1(4): 175-177.
- Ruiz-Ramos M, Minguez MI (2010) Evaluating uncertainty in climate change impacts on crop productivity in the Iberian Peninsula. *Climate Research*, 44(1): 69-82.
- Sanchez-Lorenzo A, Calbo J, Wild M (2013) Global and diffuse solar radiation in Spain: Building a homogeneous dataset and assessing their trends. *Global and Planetary Change*, 100: 343-352.
- Sansom PG, Ferro CAT, Stephenson DB, Goddard L, Mason SJ (2016) Best Practices for Postprocessing Ensemble Climate Forecasts. Part I: Selecting Appropriate Recalibration Methods. *Journal of Climate*, 29(20): 7247-7264.
- Schulzweida U (2015) CDO Climate Data Operators, User's guide. <https://code.zmaw.de/projects/cdo>.
- Semenov MA, Porter JR (1995) Climatic variability and the modeling of crop yields. *Agricultural and Forest Meteorology*, 73(3-4): 265-283.
- Sen PK (1968) Estimates of regression coefficient based on Kendalls tau. *Journal of the American Statistical Association*, 63(324): 1379-1389.
- Slingo JM, Challinor AJ, Hoskins BJ, Wheeler TR (2005) Introduction: food crops in a changing climate. *Philosophical Transactions of the Royal Society B-Biological Sciences*, 360(1463): 1983-1989.
- Smoliak BV, Wallace JM, Stoelinga MT, Mitchell TP (2010) Application of partial least squares regression to the diagnosis of year-to-year variations in Pacific Northwest snowpack and Atlantic hurricanes. *Geophysical Research Letters*, 37.
- Tao FL, Yokozawa M, Liu JY, Zhang Z (2008) Climate-crop yield relationships at provincial scales in China and the impacts of recent climate trends. *Climate Research*, 38(1): 83-94.
- Taylor KE (2001) Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research-Atmospheres*, 106(D7): 7183-7192.
- Taylor KE, Stouffer RJ, Meehl GA (2012) An overview of cmip5 and the experiment design. *Bulletin of the American Meteorological Society*, 93(4): 485-498.
- Tebaldi C, Lobell DB (2008) Towards probabilistic projections of climate change impacts on global crop yields. *Geophysical Research Letters*, 35(8).
- Tebaldi C, Smith RL, Nychka D Mearns LO (2005) Quantifying uncertainty in projections of regional climate change: A Bayesian approach (vol 18, pg 1524, 2005). *Journal of Climate*, 18(16): 3405-3405.
- Thornton P, Ewert F (2014) Making the most of climate impacts ensembles (vol 4, pg 77, 2014). *Nature Climate Change*, 4(3): 166-166.
- Trenberth KE, Caron JM, Stepaniak DP Worley S (2002) Evolution of El Nino-Southern Oscillation and global atmospheric surface temperatures. *Journal of Geophysical Research-Atmospheres*, 107(D7-8).
- Trnka M et al. (2011) Expected changes in agroclimatic conditions in Central Europe. *Climatic Change*, 108(1-2): 261-289.
- Vermeulen SJ et al. (2013) Addressing uncertainty in adaptation planning for agriculture. *Proceedings of the National Academy of Sciences of the United States of America*, 110(21): 8357-8362.
- Vicente-Serrano SM, Lopez-Moreno JI (2005) Hydrological response to different time scales of climatological drought: an evaluation of the Standardized Precipitation Index in a mountainous Mediterranean basin. *Hydrology and Earth System Sciences*, 9(5): 523-533.
- Vitart F, Ardilouze C, Bonet A, Brookshaw A, Chen M, Codorean C, Déqué M, Ferranti L, Fucile E, Fuentes M, Hendon H, Hodgson J, Kang H-S, Kumar A, Lin H, Liu G, Liu X, Malguzzi P, Mallas I, Manoussakis M, Mastrangelo D, MacLachlan C, McLean P, Minami A, Mladek R, Nakazawa T, Najm S, Nie Y, Rixen M, Robertson AW, Ruti P, Sun C, Takaya Y, Tolstykh M, Venuti F, Waliser D, Woolnough S, Wu T, Won DJ, Xiao H, Zaripov R, Zhang L (2017) The Subseasonal to Seasonal (S2S) prediction project database. *Bulletin of the American Meteorological Society*, 98(1): 163-173. doi:10.1175/BAMS-D-16-0017.1.
- Wallace JM, Fu Q, Smoliak BV, Lin P, Johanson CM (2012) Simulated versus observed patterns of warming over the extratropical Northern Hemisphere continents during the cold season. *Proceedings of the National Academy of Sciences of the United States of America*, 109(36): 14337-14342.
- Wang H et al. (2016) Monitoring winter wheat drought threat in Northern China using multiple climate-based drought indices and soil moisture during

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

- 2000-2013. *Agricultural and Forest Meteorology*, 228: 1-12.
- Watson J, Challinor AJ (2013) The relative importance of rainfall, temperature and yield data for a regional-scale crop model. *Agricultural and Forest Meteorology*, 170: 47-57.
- Watson J, Challinor AJ, Fricker TE, Ferro CAT (2015) Comparing the effects of calibration and climate errors on a statistical crop model and a process-based crop model. *Climatic Change*, 132(1): 93-109.
- Wesselink A et al. (2015) Equipped to deal with uncertainty in climate and impacts predictions: lessons from internal peer review. *Climatic Change*, 132(1): 1-14.
- Wild M (2016) Decadal changes in radiative fluxes at land and ocean surfaces and their relevance for global warming. *Wiley Interdisciplinary Reviews-Climate Change*, 7(1): 91-107.
- Wilks DS (2006) *Statistical methods in the atmospheric sciences*. Academic Press, 627 pp.
- Wilks DS (2016) The stippling shows statistically significant gridpoints: How research results are routinely overstated and over-interpreted, and what to do about it. *Bulletin of the American Meteorological Society* (in press).
- Wold S et al. (2009) The PLS model space revisited. *Journal of Chemometrics*, 23(1-2): 67-68.
- Wu ZH, Huang NE, Wallace JM, Smoliak BV, Chen XY (2011) On the time-varying trend in global-mean surface temperature. *Climate Dynamics*, 37(3-4): 759-773.
- Xiao D et al. (2016) Comparison of winter wheat yield sensitivity to climate variables under irrigated and rain-fed conditions. *Frontiers of Earth Science*, 10(3): 444-454.
- Xie SP et al. (2015) Towards predictive understanding of regional climate change. *Nature Climate Change*, 5(10): 921-930.

Supplementary material

Assessing GLAM-wheat simulation to estimate variability and projected trend of wheat yield in Spain

Sara Hernández-Barrera^a; Concepción Rodríguez-Puebla^a; Stewart Jennings^b and Andrew J. Challinor^b

1. Provinces used in the study

Table S1. Correspondence between provinces and symbol, geographic parameters, wheat surface and production averaged for 2012, 2013 and 2014 years

Provinces	Symbol	Latitude	Longitude	Altitude	Surface (10 ³ Ha)	Production (10 ⁶ kg)
La Coruña	ac	43°20'N	08°25'W	67	1928	6263
Lugo	lg	43°02'N	07°35'W	465	3761	8892
Ourense	or	42°19'N	07°55'W	148	8923	27492
Pontevedra	pv	42°26'N	08°40'W	261	521	1174
Asturias	as	43°15'N	06°00'W	10	52	60
Cantabria	cn	43°10'N	04°00'W	52	568	989
Álava	aa	42°59'N	02°38'W	508	24995	135303
Vizcaya	vz	43°15'N	02°55'W	34	0	0
Navarra	nv	42°40'N	01°40'W	449	60799	324338
La Rioja	lr	42°20'N	02°20'W	352	25351	158526
Huesca	hs	42°08'N	00°25'W	542	37492	203804
Teruel	te	40°20'N	01°08'W	912	39890	86312
Zaragoza	zg	41°39'N	00°53'W	240	130636	339258
Barcelona	br	41°21'N	02°10'E	6	22802	90228
Gerona	gn	41°58'N	02°46'E	149	10464	60197
Lérida	ld	41°37'N	00°39'E	155	36984	203154
Tarragona	tg	41°05'N	01°17'E	76	6864	24805
Ávila	av	40°39'N	04°43'W	1130	31457	84304
Burgos	bu	42°21'N	03°41'W	881	218898	956791
León	ln	42°38'N	05°34'W	913	36435	234515
Palencia	pl	42°01'N	04°34'W	749	99588	422299
Salamanca	sl	40°58'N	05°39'W	790	64133	194968
Segovia	sg	40°57'N	04°10'W	1005	66235	189390
Soria	sr	41°45'N	02°28'W	1080	99400	283241
Valladolid	vd	41°38'N	04°43'W	854	66802	263057
Zamora	zm	41°30'N	05°45'W	667	60440	208050
Madrid	md	40°25'N	03°45'W	667	24314	97443
Albacete	ab	39°00'N	01°50'W	704	55958	206427
Ciudad R.	cr	38°59'N	03°55'W	629	49195	91414

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

Cuenca	cu	40°05'N	02°10'W	945	33892	95929
Guadalajara	gj	40°37'N	03°12'W	685	68889	173479
Toledo	td	39°51'N	04°01'W	540	60334	142736
Alicante	an	38°23'N	00°30'W	82	740	3879
Castellón	cs	39°58'N	00°03'W	25	631	897
Valencia	vn	39°20'N	00°40'W	11	1370	2570
Murcia	mr	38°05'N	01°10'W	75	5502	14669
Badajoz	bd	38°50'N	06°59'W	192	78310	146977
Cáceres	cc	39°26'N	06°23'W	459	5901	8317
Almería	am	36°52'N	02°27'W	21	1978	1808
Cádiz	cd	36°30'N	06°20'W	8	61266	171662
Córdoba	co	37°50'N	04°50'W	91	71838	210967
Granada	gd	37°10'N	03°35'W	680	13941	27853
Huelva	hl	37°18'N	06°57'W	26	14967	43266
Jaén	ja	37°46'N	03°47'W	510	8293	17115
Málaga	mg	36°43'N	04°23'W	7	20740	47641
Sevilla	sv	37°23'N	05°58'W	31	146645	444354

2. CMIP5 models used in this study (<https://esgf-data.dkrz.de/projects/esgf-dkrz/>)

Table S2. Models from CMIP5 dataset used in our analysis

Model acronym	Model Name	Center	Resolution
CCSM4	Community Climate System Model, version 4	National Center of Atmospheric Research (NCAR), USA	0.9° (lat)x 1.25 (lon), L27
CMCC-CESM	Centro Euro-Mediterraneo per I Cambiamenti Climatici Carbon Cycle Earth System Model	Centro Euro-Mediterraneo per I Cambiamenti Climatici (CMCC), Italy	1.875° x 1.875° (T63), L95°
CNRM-CM5	Centre National de Recherches Météorologiques Coupled Global Climate Model, version 5	Centre National de Recherches Meteorologiques (CNRM-CERFACS), France	TL127, L31
GFDL-ESM2M	Geophysical Fluid Dynamics Laboratory Earth System Model with Modular Ocean Model, version 4 (MOM4) component	NOAA Geophysical Fluid Dynamics Laboratory (NOAA-GFDL), USA	2.0°(lat) x2.5° (lon) M45, L24

HadGEM2-CC	Hadley Centre Global Environment Model, version 2, Carbon Cycle	Met Office Hadley Centre (MOHC), UK	1.25° (lat) x 1.875 (lon), N96, L60
HADGEM2-ES	Hadley Centre Global Environment Model, version 2, Earth System	Met Office Hadley Centre (MOHC/INPE), UK	1.25° (lat)x 1.875 (lon), N96, L38
MIROC5	Model for Interdisciplinary Research on Climate, version 5	National Institute for Environmental Studies and Japan Agency for Marine-Earth Science and Technology, Japan	1.40625° x 1.40625°, T85, L40
MPI-ESM-MR	Max Planck Institute Earth System Model, medium resolution	Max Planck Institute for Meteorology, Germany	1.8° x 1.8°, T63, L95
NorESM1-M	Norwegian Earth System Model, version 1, intermediate resolution.	Norwegian Climate Centre (NCC), Norway	1.9°(lat) x 2.5°(lon), L26

3. GLAM-wheat parameters

The GLAM optimiser was applied in order to obtain optimal GLAM parameter sets for winter wheat. The optimiser runs GLAM for two regions of Spain using observed climate data and parameter sets from within pre-defined ranges by Li, S. (2008). The optimisation procedure was carried out in the period 1980-2011. Table S3 shows values of parameters set of optimisation procedure for winter wheat yield of each region and their ranges.

Table S3. GLAM-winter wheat parameters set varied in the optimisation procedure and their ranges

Parameter	Description	Min	Max	Region 1	Region 2	Reference
$\left(\frac{\partial L}{\partial t}\right)_{Emax}$	Max daily increase in LAI (per day)	0.06	0.15	0.0992	0.0932	Friend et al. (1962); Kemp and Blacklow (1982)
C_G	Soil heat flux constant	0.22	0.51	0.3656	0.3618	Choudhury et al. (1987)
Scr	Critical value of soil water stress factor for leaves	0.5	1.0	0.9490	0.5378	Meyer and Green (1981)
EFV	Extraction front velocity (cm day ⁻¹)	0.5	3.0	1.0409	1.7013	Barley (1970)

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

Z_{ed}	Depth of soil from which evaporation occurs (cm)	8.4	84.0	9.7720	9.7720	Challinor et al., (2004)
A	Mean albedo of the surface	0.17	0.38	0.2691	0.2659	Fuller & Ottke (2002)
C_{d3}	Constant for drainage	0.75	0.95	0.9440	0.9440	Challinor et al. (2004)
$\left(\frac{d(L_p)}{d(LAI)}\right)$	Root length density by volume	0.5	5.0	1.2639	4.7027	Gajri & Prihar (1985)
K_{DIF}	Uptake diffusion coefficient (cm^2/day)	0.06	0.14	0.0398	0.0656	Challinor et al. (2004)
L_{cr}	LAI below which transpiration is physiologically limited	0.6	1.2	0.8834	0.7552	GLAM-R2 (2009)
T_{Tmax}	Max potential transpiration rate (cm/day^{-1})	0.15	0.4	0.2546	0.2546	Challinor et al. (2004)
TE	Transpiration efficiency (Pa)	1.3	4.5	1.4000	1.4000	Stöckle & Nelson (2000)
$\frac{\partial H_I}{\partial}$	Rate of change of harvest index (per day)	0.0042	0.0098	0.0074	0.0074	GLAM-R2 (2009)
$E_{TN,max}$	Maximum of normalised transpiration efficiency (g/kg)	1.5	5.0	3.0	3.0	Cooper (1987)
T_{tt2}	Grain-filling to end of grain filling ($^{\circ}K$)	328	543	365.000	365.000	Li, S. (2008)
T_{tt3}	End of grain filling to harvest ($^{\circ}K$)	80	100	48.0000	48.0000	Li, S. (2008)
EN	Intrinsic earliness	0.6	1.0	0.7725	0.7725	Cao and Moss (1997)
V_R	Vernalisation requirement (days)	0	55	48.6393	50.3454	Cao and Moss (1997)

4. GLAM-wheat re-calibration by empirical quantile mapping correction

To reduce errors and improve the reliability of the GLAM-wheat yield simulations we applied empirical quantile mapping (eQM) bias correction. The corrections were applied to individual provinces using a quantile-based downscaling matlab script.

Figure S1 compares the frequency distribution of the wheat-yield observed, the corresponding derived from GLAM simulation before and after re-calibration in case of region 2. The performance of the eQM re-calibration improve the agreement between GLAM-wheat and OBS-wheat (Figures 2 of the main text).




Figure S1. Frequency distribution of OBS-wheat (blue) and GLAM-wheat before eQM (red) and after eQM (green).

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

5. Taylor diagram

Spatial comparison of metrics: correlation, root-mean-square difference and standard deviation of the GLAM-wheat against the OBS-wheat for provinces (points) and averaged wheat yield of both regions 1 and 2




Figure S2. Taylor diagram showing the skill of the GLAM-wheat in each province and regions 1 (in green) and 2 (in brown). The reference is the normalized standard deviation of wheat observed. The standard deviations of the simulations are relative to the observations. Points 1 and 2 indicate where the simulations for regions 1 and 2 are located. The solid circle lines represent the RMSE difference with an interval of 0.25

6. Effects of ENSO events on climate variables associated with wheat yield

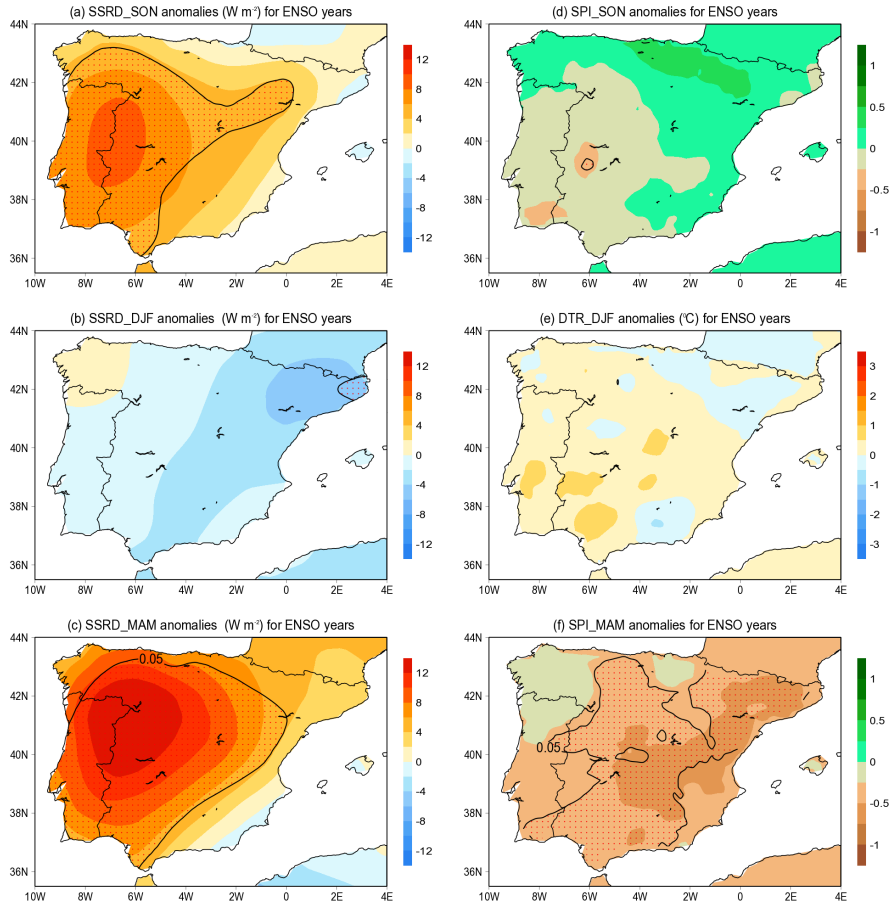


Figure S3. For ENSO years: (a,b and c) anomalies of SSRD ($W m^{-2}$) in autumn, winter and spring; (d and f) anomalies of SPI (standard deviation units) in autumn and spring; (e) composite of DTR ($^{\circ}C$) in winter. Dotted areas correspond at the 0.05 level for the differences using a 2-sided Student-t test. Left column is for surface solar radiation (SSRD) in autumn (SON), winter (DJF) and spring (MAM). Right column is for standardized precipitation index (SPI) in autumn (d) and spring (f), and for the diurnal temperature range (DTR) in winter (e)

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

7. Assessment of EMP_SSRD-wheat

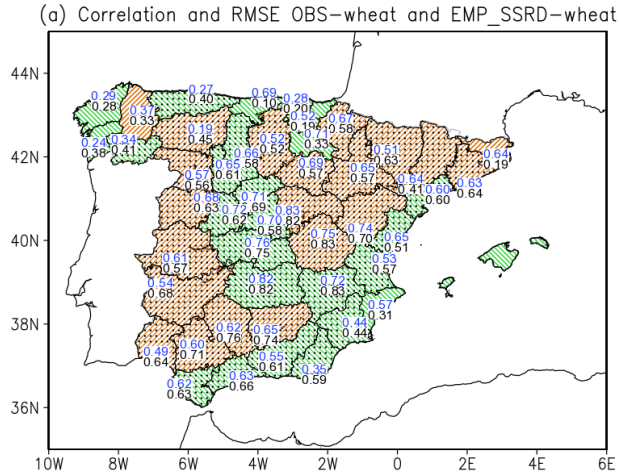


Figure S4. As Figure 2b but for EMP_SSRD-wheat

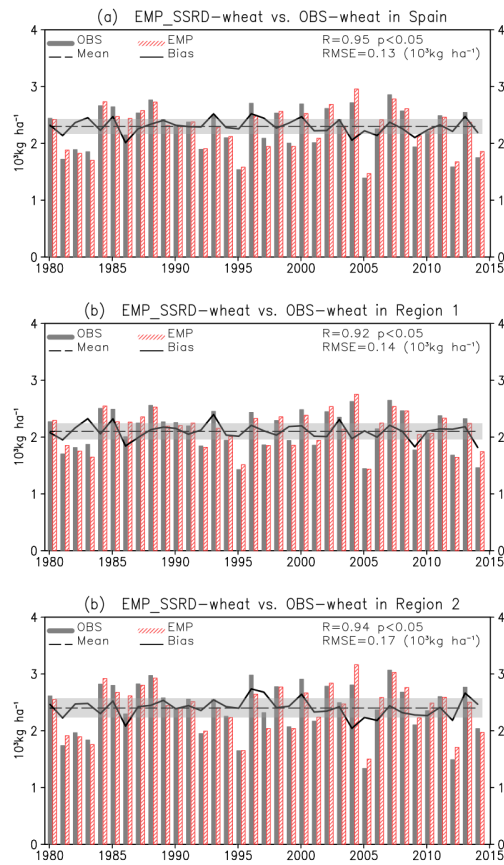


Figure S5. As Figure 7 but for EMP_SSRD-wheat

8. Projections of climate variables over Spain using CMIP5 outputs

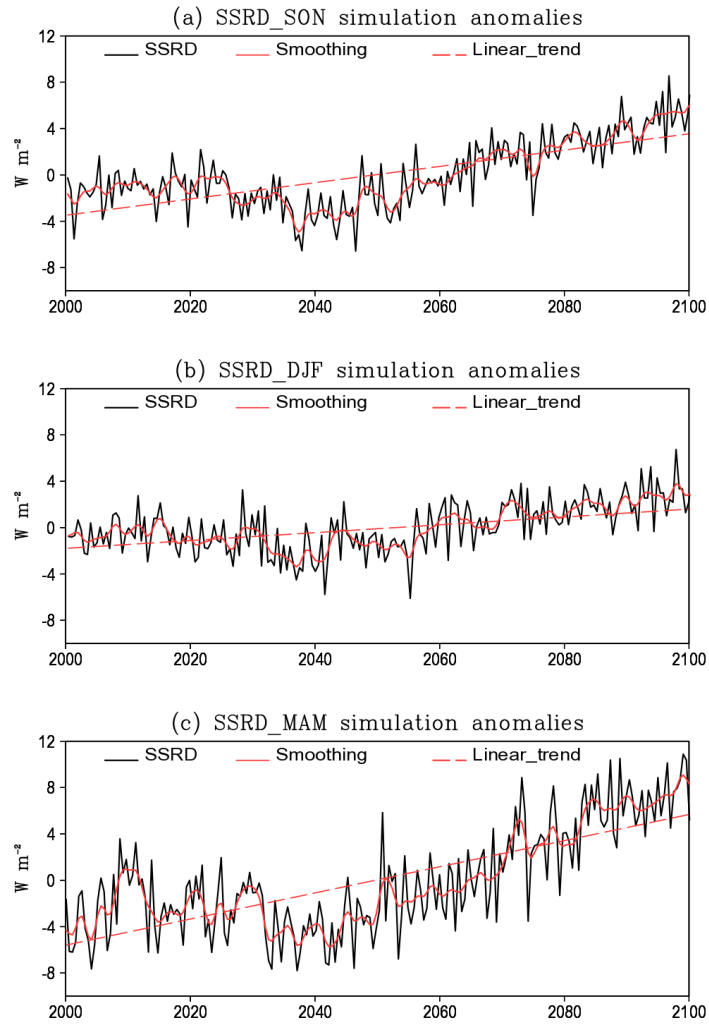


Figure S6. Multi-model simulation anomalies of the spatially averaged time series across Spain of the SSRD in Wm^{-2} : (a) in SON, (b) in MAM, and (c) in DJF. The black line represents the simulation, the solid red line represents the 15-year smoothing, and the dashed red line indicates the linear trend

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

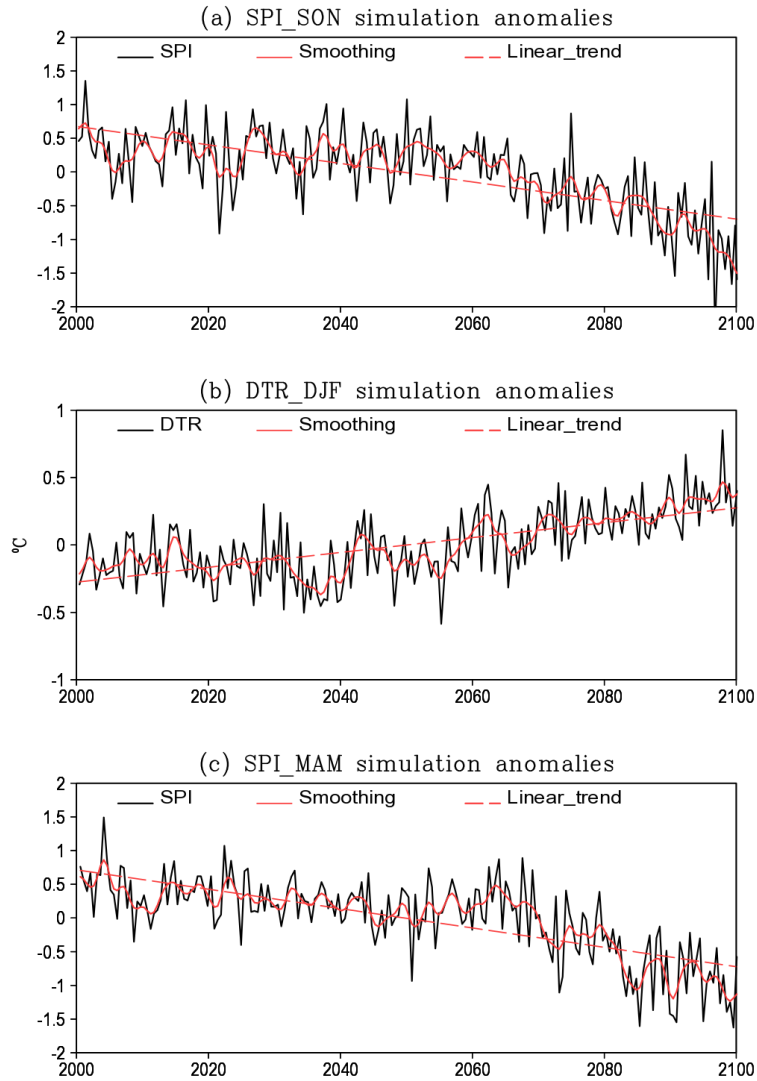


Figure S7. Multi-model simulation anomalies of the spatially averaged time series across Spain of the SPI: (a) in SON, (c) in MAM, and for DTR in DJF (b). The black line represents the simulation, the solid red line represents the 15-year smoothing, and the dashed red line indicates the linear trend

References

- Barley KP, 1970: The configuration of the root system in relation to nutrient uptake. *Adv. Agron.*, 22, 159-201
- Cao W and Moss DN, 1997: Modeling phasic development in wheat: A conceptual integration of physiological components. *J. Agric. Sci.*, 129, 163-172.
- Challinor AJ, Wheeler TR, Slingo JM, Craufurd PQ, Grimes DIF, 2004: Design and optimisation of a large-area process-based model for annual crops. *Agric. Forest Meteorol.*, 124, 99-120.
- Choudhury BJ, Idso SB, Reginato RJ, 1987: Analysis of an empirical model for soil heat flux under a growing wheat crop for estimating evaporation by an infrared temperature based energy balance equation. *Agric. Forest Meteorol.*, 39, 283-297.
- Cooper PJM, Gregory PJ, Tully D, Harris HC, 1987: Improving water use efficiency of annual crops in the rainfed farming systems of West Asia and North Africa. *Exp. Agr.*, 23, 113-158.
- Déqué M, 2007: Frequency of precipitation and temperature extremes over France in an anthropogenic scenario: Model results and statistical correction according to observed values. *Global and Planetary Change*, 57 (1{2), 16{26, doi:10.1016/j.gloplacha.2006.11.030.
- Friend DJC, Helson VA, Fisher JE, 1962: Leaf growth in Marquis wheat, as regulated by temperature, light intensity, and daylength. *Can. J. Bot.*, 40, 1299-1311.
- Gajri PR and Prihar SS, 1985: Rooting, water use and yield relations in wheat on loamy sand and sandy loam soils. *Field Crops Res.*, 12, 115-132.
- GLAM-R2, 2009: The General Large Area Model for annual crops (GLAM). Release version 2. www.see.leeds.ac.uk/redmine/public/projects/glam.
- Kemp DR and Blacklow WM, 1982: The responsiveness to temperature of the extension rates of leaves of wheat growing in the field under different levels of nitrogen fertilizer. *J. Exp. Bot.*, 33, 29-36.
- Li S, 2008: Investigating the impacts of climate change on wheat in China. PhD thesis, University of Reading, Reading, UK.
- Meyer WS and Green GC, 1980: Water use by wheat and plant indicators of available soil water. *Agron. J.*, 72, 253-257.
- Nicklin K, 2013: Seasonal crop yield forecasting in semi-arid West Africa PhD thesis, University of Reading, Reading, UK.
- Stöckle CO and Nelson RL, 2000: *Cropsyst User's Manual (Version 3.0)*. Biological Systems Engineering Department, Washington State University, Pullman, WA, 235 pp.

5.3. Artículo “Evaluación de las simulaciones de GLAM para estimar la variabilidad y tendencia del rendimiento de trigo en España”

CAPÍTULO 6

Conclusiones y trabajo futuro



6.1. Introducción

En este capítulo se presentan los principales resultados y conclusiones de esta tesis doctoral. Se divide en tres secciones: la sección 6.1 incluye una introducción sobre cómo se recogerán y enlazarán los resultados más importantes de las diferentes partes de esta tesis. En la sección 6.2 se especifican los resultados de esta investigación, e incluye tres subsecciones en las que se extraen las conclusiones y aportaciones científicas de cada artículo. Por último, la sección 6.3 expone las posibles líneas de investigación futura que darían continuidad a los estudios realizados en esta tesis doctoral.

6.1. Introducción

El estudio de las interacciones del clima y la productividad de trigo se ha abordado mediante modelos agrícolas elaborados desde las perspectivas empírica y mediante el análisis de los procesos físicos que controlan el desarrollo del cultivo. Por un lado, se incluyen las relaciones entre la variabilidad de la productividad de trigo y el clima. Y por otro lado, se indican las proyecciones de productividad de trigo en condiciones de cambio climático.

Los modelos agrícolas empíricos se determinaron mediante un estudio de la influencia de diferentes variables climáticas que afectan a la variabilidad de las producciones. Estas variables se clasificaron atendiendo al dominio espacial considerado. De este modo diferenciamos, por una parte, los modelos empíricos que incluyen los efectos de la temperatura y precipitación en el dominio espacial de España, y por otra, los modelos empíricos que incluyen los efectos de radiación, circulación atmosférica y teleconexiones en el dominio Euro-Atlántico y a gran escala.

Un aspecto novedoso de la investigación fue la incorporación del método regresión parcial por mínimos cuadrados (PLS) para encontrar la asociación entre el clima y la producción agrícola, así como para identificar los modos de variabilidad de las variables climáticas que constituyen los modelos agroclimáticos empíricos. Este método es muy útil ya que permite extraer las señales de variabilidad conjuntas entre la productividad de trigo y el clima. Posteriormente, estos modos de variabilidad se utilizan para seleccionar los predictores más significativos y evitar la información redundante en el modelo agroclimático.

Las series de rendimiento de trigo muestran una componente de tendencia que interfiere a la hora de elaborar los modelos. Dado que la tendencia puede estar más relacionada con las mejoras tecnológicas que con la propia variabili-

dad climática, se ha incorporado un método para filtrar dicha componente de tendencia, el cual es adaptativo a los datos y no requiere una función matemática previamente definida, como son los métodos lineales o cuadráticos. Este procedimiento se basa en la descomposición empírica en modos de variación de la serie temporal (EEMD).

En esta investigación se ha utilizado el modelo basado en procesos GLAM por las razones indicadas en el Capítulo 5. En primer lugar, se evaluó GLAM para investigar su representatividad en simular el rendimiento de trigo. La evaluación se realizó de dos maneras. Por una parte, mediante un estudio de métricas estadísticas como el coeficiente de correlación de Pearson y el error cuadrático medio. Y por otra, se ha aplicado una evaluación específica y novedosa mediante un análisis de la respuesta de GLAM a las variables climáticas que incluyen los modelos empíricos. Esta evaluación tiene un gran interés por las aplicaciones de GLAM, junto con las predicciones estacionales, para proporcionar predicciones de rendimiento de trigo, y así, poder aportar un servicio muy demandado por el sector agrícola.

En esta parte de la tesis observamos que las diferencias más notables entre los resultados del trigo simulado con GLAM y las observaciones ocurrían en años en los que se presentaban el fenómeno El Niño. Por ello, se ha analizado la influencia de fenómenos El Niño/La Niña en la variabilidad del trigo observado y en los resultados de las simulaciones con GLAM. Como consecuencia de este análisis surge la conveniencia de utilizar modelos híbridos, estadísticos y basado en procesos, para conjuntar los efectos de la variabilidad climática y de las teleconexiones.

Los diferentes modelos agrícolas derivados: los dos estadísticos, el basado en procesos y el híbrido, se han aplicado para proporcionar las proyecciones del rendimiento de trigo en condiciones de cambio climático. Para ello, se han utilizado los datos climáticos de modelos CMIP5. Los métodos aplicados para obtener las proyecciones difieren según si los modelos agrícolas son empíricos o basado en procesos. Para obtener las proyecciones con modelos agrícolas empíricos se aplica el método PLS en modo espacial. Sin embargo, las proyecciones con modelos basados en proceso se basan en la integración de los datos diarios CMIP5 en el modelo GLAM. Finalmente, se analiza la incertidumbre de las diferentes proyecciones.

6.2. Conclusiones específicas

6.2. Conclusiones específicas

6.2.1. Efectos del rango térmico diario y sequía en la productividad del trigo en España

El objetivo de este estudio era analizar la respuesta del rendimiento del trigo en España a los procesos climáticos utilizando variables climáticas de escala regional y métodos estadísticos, y proyectar el rendimiento del trigo bajo los escenarios del cambio climático. Por lo tanto, las principales conclusiones que responden a las cuestiones planteadas en la sección 5.1 se enumeran a continuación:

- ◇ La variabilidad del rendimiento del trigo en España se representa con mayor significación con las variables climáticas derivadas de la precipitación y la temperatura. Éstas son: el índice de precipitación estandarizado (SPI) y rango diario de temperatura (DTR).
- ◇ El SPI influye de forma positiva en las estaciones de otoño y primavera. Por el contrario, el DTR influye negativamente en el invierno.
- ◇ El modelo agroclimático empírico basado en el SPI y el DTR explica un 63 % de la variabilidad del rendimiento del trigo.
- ◇ El modelo obtenido en el periodo observacional se aplica para obtener proyecciones de trigo utilizando los modelos de Circulación General CMIP5, los escenarios históricos y RCP8.5. El método que permite derivar las proyecciones es la regresión parcial por mínimos cuadrados en modo espacial.
- ◇ Las proyecciones del rendimiento del trigo se obtienen a partir de datos de precipitación, temperatura máxima y mínima de los modelos individuales CMIP5, a partir de los cuales se derivan los datos del SPI y DTR. Las proyecciones obtenidas indican una reducción del rendimiento de trigo para el siglo XXI (32 %). En esta proyección no se tuvo en cuenta el ajuste de corrección de sesgos en percentiles o empirical quantile mapping (eQM). Posteriormente, para la comparación de proyecciones de modelos empíricos y basado en procesos se tuvo en cuenta la corrección eQM,

obteniendo en este caso una disminución del rendimiento del trigo del 8 %. La dispersión en las proyecciones de rendimiento de trigo se debe, en parte, a la incertidumbre de las proyecciones de precipitación. Por esta razón, se decidió la búsqueda de predictores a gran escala, cuyos resultados forman parte del segundo artículo.

- ◇ Los resultados de disminución del rendimiento de trigo se justifican mediante un estudio de las proyecciones de precipitación y del DTR. Los modelos CMIP5 informan de una disminución de precipitación en otoño y primavera y de un aumento de DTR en invierno.

6.2.2. El rendimiento del trigo en España y su asociación con los patrones de radiación solar

Este trabajo surge por la necesidad de encontrar un modelo agroclimático basado en predictores que disminuyan la incertidumbre de las proyecciones del rendimiento del trigo en España. Para ello se consideraron variables a gran escala y se plantearon las cuestiones mostradas en la sección 5.2, a las cuales se responde con las conclusiones que se exponen a continuación:

- ◇ Se realizó una clasificación inicial del rendimiento de trigo a partir de los datos provinciales. Para esta clasificación se aplicó el método de conglomerados K-medias, obteniéndose una partición en dos regiones con diferente variabilidad.
- ◇ Se aplicó el método PLS a diferentes variables a gran escala como presión a nivel del mar (MSL), altura geopotencial a 500 hPa (Z500), viento zonal a 250 hPa (U250), temperatura superficial del mar (SST) y radiación solar (SSRD). El modelo seleccionó la variable SSRD para las diferentes fases del desarrollo del trigo desde su crecimiento hasta la madurez, es decir, influye en las estaciones de otoño, invierno y primavera.
- ◇ Se demostró que el modelo agroclimático empírico, basado en la SSRD, recoge los efectos de otras variables a gran escala, como el Z500, U250, de la SST del Pacífico en primavera y de la SST en el Atlántico Norte en invierno. Además, este modelo incluye los efectos de las teleconexiones: la SSRD está asociada con el índice de la AMO en otoño, con los índices de la NAO y el EA en invierno, y con el índice SCAND en primavera.

6.2. Conclusiones específicas

- ◇ El modelo basado en la SSRD describe con mayor significación el rendimiento de trigo observado que el modelo basado en SPI y DTR. Los resultados indican que los rendimientos estimados con el modelo basado en la SSRD son significativos para el 71 % de las provincias, frente al 65 % de las provincias en el caso del modelo basado en el SPI y DTR. Además, los modos de variación de SSRD incluyen los efectos de la precipitación y temperatura ya que están correlacionados negativamente con los correspondientes del SPI de otoño y primavera, y positivamente con el DTR de invierno.
- ◇ Las proyecciones del rendimiento de trigo se obtienen mediante los datos de SSRD de los modelos CMIP5 y aplicando el método PLS en modo espacial. Los resultados predicen una disminución que varía entre 6 y 8 % sin aplicar eQM, y del orden del 13 % después de la corrección de sesgos mediante eQM.
- ◇ En esta investigación se comprueba que la incertidumbre de las proyecciones de los modelos empíricos basados en SSRD disminuye respecto a la de los modelos basados en SPI y DTR. Para ello se utilizó la relación entre la señal de variabilidad de tendencia forzada y la tendencia asociada a la variabilidad interna y estructural de los diferentes modelos. Estos resultados confirman la hipótesis de partida sobre la fiabilidad de las proyecciones de los modelos empíricos basados en predictores a gran escala respecto a la de los predictores a escala regional.
- ◇ Se justificó la disminución del rendimiento de trigo con las proyecciones de aumento de SSRD que indican los modelos CMIP5 para el siglo XXI.
- ◇ Si bien los modelos empíricos son fiables para el periodo observacional, podemos pensar que el ajuste no sea válido para otras condiciones climáticas, siendo esta una de las limitaciones de los modelos empíricos. Por ello se planteó la utilización de otro tipo de modelos, basado en procesos, que constituyen los resultados del tercer artículo.

6.2.3. Evaluación del modelo agrícola GLAM para caracterizar la variabilidad y tendencia del trigo en España

El objetivo de este estudio fue evaluar la variabilidad del rendimiento del

Capítulo 6. Conclusiones y trabajo futuro

trigo en España utilizando las simulaciones del modelo agrícola basado en procesos GLAM. Por ello, las principales conclusiones que responden a las cuestiones planteadas en la sección 5.3 se enumeran a continuación:

- ◇ La evaluación estadística mediante el coeficiente de correlación y el error cuadrático medio indica que cuando se aplica GLAM en regiones amplias (por ejemplo, en las dos regiones en las que se ha dividido España en relación a la variabilidad del trigo), GLAM es capaz de simular la variabilidad del trigo en España, con un intervalo de significación superior al 95 %. Sin embargo, la evaluación provincial, indica que GLAM caracteriza significativamente el trigo en un 56 % de la superficie, después de haber aplicado la corrección de sesgos eQM.
- ◇ La evaluación de GLAM considerando la influencia de las variables climáticas, muestra que la respuesta de GLAM respecto al trigo observado es: en primavera mayor (menor) a la SSRD (al SPI); en invierno menor (mayor) a la SSRD (al DTR); en otoño menos significativa a SSRD y el SPI que el trigo observado.
- ◇ Un resultado de gran interés indica que los años con mayores diferencias entre las simulaciones con GLAM y las observaciones se presenta cuando el índice ENSO es más intenso. Por un lado, se obtiene que los años El Niño causan una disminución de la producción de trigo. Por otro, que los resultados de trigo derivados de GLAM responden de forma más débil a las teleconexiones que el trigo observado.
- ◇ Se demostró que la influencia del ENSO en el trigo se debe a los efectos que el ENSO produce en las variables climáticas asociadas al trigo. Y se argumenta que GLAM puede no capturar los efectos de los extremos climáticos en el trigo.
- ◇ A partir de los resultados de este trabajo parece necesario combinar los modelos empíricos y basado en procesos para incluir las ventajas de cada uno y compensar ciertas limitaciones. Por ejemplo, incluir los efectos de las variables climáticas y teleconexiones, y atenuar la dependencia de los parámetros obtenidos de los modelos empíricos para el periodo observacional.
- ◇ Por ello se combinó GLAM y el modelo empírico basado en la SSRD. Los resultados indican mejoras notables en cuanto a la significación de la

6.3. Futuras líneas de investigación

correspondencia espacial y temporal (la varianza que describe el modelo híbrido es del 83 % frente al 52 % del modelo GLAM). La significación espacial es también mayor en el caso del modelo híbrido (89 %) frente a GLAM (56 %).

- ◇ Se aplicaron los modelos para proyectar el rendimiento de trigo en condiciones de cambio climático, utilizando los modelos de circulación general CMIP5. Se obtiene los siguientes cambios porcentuales: 42 % en el caso de GLAM y 25 % en el caso del modelo combinado GLAM y empírico basado en SSRD.
- ◇ Todos los modelos proporcionan una tendencia de disminución del rendimiento de trigo, con menor incertidumbre para los modelos GLAM y el combinado GLAM-empírico. Se cuantificó la incertidumbre de las proyecciones mediante el cálculo del índice SNR. Obteniendo valores de -3.8 y -2.9 para GLAM y el modelo híbrido, respectivamente.
- ◇ Para justificar esta tendencia de disminución del rendimiento de trigo por los efectos del cambio climático se obtuvieron las proyecciones de las variables que influyen en la variabilidad del trigo. Se observa una tendencia creciente para la SSRD y el DTR y decreciente para la precipitación.

6.3. Futuras líneas de investigación

Los planteamientos iniciales para el desarrollo de esta investigación se fueron modificando y adaptando atendiendo a los resultados obtenidos y a las nuevas cuestiones que surgían. Al concluir la tesis siguen planteándose cuestiones y posibles líneas de investigación que se continuarán en posteriores estudios. Algunas de las cuales se indican a continuación:

- ◇ Evaluar los modelos propuestos utilizando predicciones estacionales, y así, proporcionar un servicio al sector agrario. Esta investigación es prioritaria dentro del ámbito de la climatología aplicada. El sector agrícola necesita productos de predicción para la toma de decisiones sobre la siembra, la cosecha, el manejo del agua, la selección del tipo de cultivo, entre otros. Por otro lado, las predicciones meteorológicas estacionales disponen de una base de datos sub-estacionales y estacionales (S2S; Vitart et al.

2017) para la aplicabilidad operacional, cuyo objetivo es proporcionar pronósticos que pueden abarcar un rango desde 2 semanas a 12 meses, con el fin de predecir eventos extremos u otros eventos, los cuales pueden tener un impacto social. Por lo que, un servicio de información climático útil para la agricultura, sería la estimación del rendimiento de cultivos a partir de la combinación de los modelos estacionales o sub-estacionales y los modelos agrícolas. De manera que, utilizando los modelos agroclimáticos obtenidos en esta tesis doctoral, junto con las predicciones climáticas sub-estacionales y estacionales, se puede predecir los rendimientos del trigo, así como los efectos del cambio climático en las producciones. Del mismo modo, se podrían realizar predicciones estacionales para otros cultivos de interés.

- ◇ Investigar sobre diferentes métodos para corrección de sesgos y optimización de los modelos. Además, determinar cómo las diferentes correcciones afectarían a las predicciones y proyecciones de rendimientos agrícolas.
- ◇ Aplicar la metodología utilizada en esta tesis doctoral a otras producciones agrícolas como a olivos, viñedos y cítricos para determinar el impacto del cambio climático.
- ◇ En este trabajo de investigación se han obtenido asociaciones entre el rendimiento de trigo e índices de teleconexión climática. Sería interesante profundizar si estas influencias son manifestaciones de los fenómenos extremos asociados a las teleconexiones.
- ◇ El método EEMD se ha utilizado para aislar las tendencias de las proyecciones del rendimiento del trigo de los modelos individuales y del multimodelo. Sería interesante aplicarlo para extraer las variaciones de otras fluctuaciones interanuales y decanales en diferentes producciones.
- ◇ En esta investigación no se han tenido en cuenta los efectos del CO_2 aunque sus posibles beneficios todavía están en debate. Supit et al. (2012) informaron que el rendimiento de trigo aumentaría por los efectos del CO_2 , mientras que Asseng et al. (2013) y Deryng et al. (2014) mostraron que provocará un impacto negativo sobre los rendimientos de trigo en toda Europa. Teniendo en cuenta estos resultados, sería interesante proyectar el rendimiento del trigo en España, considerando los efectos del CO_2 , y comparar los resultados con los obtenidos en esta tesis doctoral.

6.3. Futuras líneas de investigación

- ◇ Ampliar las investigaciones sobre la incertidumbre de las proyecciones. En esta tesis se ha determinado como medida de la incertidumbre la relación señal-ruido que cuantifica la tendencia forzada y la tendencia correspondiente a variabilidad interna y estructural. No obstante, Hawkins & Sutton (2009) exponen que la incertidumbre de los modelos también puede deberse, además de la variabilidad interna, al forzamiento radiativo, puesto que diferentes modelos simulan cambios algo diferentes en el clima, ante el mismo forzamiento radiativo.

Capítulo 6. Conclusiones y trabajo futuro

CAPÍTULO 7

Conclusions and future work



7.1. Introduction

This chapter includes main results and conclusions of this dissertation. It is divided into three sections: section 6.1 provides an introduction on how the most important results of the different parts of this research have been collected and linked. In section 6.2 the results of this research are specified. It includes three subsections, in which the conclusions and scientific contributions of each article are extracted. Finally, section 6.3 shows the possible future research lines that could provide continuity to the studies carried out in this dissertation.

7.1. Introduction

Study of climate interactions and wheat yield has been addressed through crop models developed from empirical perspectives and through the analysis of the physical processes that manage crop growth. On the one hand, the relationships between wheat yield variability and climate are analysed, and on the other, the projections of wheat yield under climate change conditions are indicated.

Empirical agro-climate models were determined through a study of the influences of different climate variables that can affect yield variability. These variables were classified according to the spatial distribution considered. We thus differentiated between the empirical models that include the effects of temperature and precipitation over the spatial domain of Spain and the empirical models that incorporate radiation effects, atmospheric circulation and teleconnection patterns over the Euro-Atlantic and on a large-scale.

Throughout this thesis different methods have been presented to analyse the data, with the PLS method being an innovative approach to identify the association between climate and crop yield, as well as to determine the variability modes of the climate variables that provide the empirical agro-climate models. This method captures the climate signals that covariate with wheat yield. These variability modes are used to extract the potential predictors employed to estimate the empirical agro-climate model and to exclude co-variability among predictors.

Wheat yield time series show a trend component which interferes when making the models. Much of the yield increase is likely due to improved crop management rather than climate variability. Therefore, the trend component is filtered out by applying EEMD, which is an adaptive approach to decons-

tructing a time series without linear or stationary assumptions.

In this investigation, the process-based GLAM model was used for the reasons explained in Chapter 5. First, GLAM was assessed to investigate its ability to simulate wheat yield, and this evaluation was performed in two different ways. On the one hand, the skill of GLAM is measured by computing the Pearson correlation coefficient and Root Mean Square Error. On the other hand, a specific and novel assessment was applied to analyse GLAM response to climate variables included in the empirical models. This assessment is of great interest for GLAM applications, together with seasonal climate prediction, to provide forecasts of wheat yield and thus provide the agricultural sector with a much needed climate service. In this part of the thesis, it was observed that there are greater differences between wheat yield simulated with GLAM and the observations in ENSO years. To support this idea, the impacts of El Niña/La Niña on variability of observed wheat yield and the simulations obtained with GLAM were analysed. As a result of this analysis, it was considered advisable to use hybrid, empirical and process-based models to combine the influences of climate drivers and the effects of teleconnection indices.

The different agricultural models derived, the two statistical ones, the process-based and the hybrid models, were applied to provide the wheat yield projections under warming conditions using outputs of CMIP5 models. Different methodologies were applied to obtain the projections depending on whether the crop models were empirical or process-based. Projections obtained with empirical agro-climate models were derived by applying PLS to the spatial dimension. However, projections obtained from the process-based model were based on introducing the daily data from the CMIP5 model in GLAM. Finally, the uncertainty of different projections was quantified.

7.2. Specific conclusions

7.2.1. Effects of diurnal temperature range and drought on wheat yield in Spain

This study aims to analyse the wheat yield response to climate processes throughout Spain by using regional climate variables and statistical methods, and to project wheat yield under climate change scenarios. Therefore, the main conclusions drawn in answer to the issues raised in section 5.1 are the following:

7.2. Specific conclusions

- ◇ Climate variables derived from precipitation and temperatures: the standardized precipitation index and diurnal temperature range are the major processes for characterizing wheat yield variability in Spain.
- ◇ SPI has a positive effect on autumn and spring. However, DTR has a negative influence in winter.
- ◇ The empirical agro-climate model based on SPI and DTR explains 63 % of wheat yield variability.
- ◇ The empirical model obtained in the observational period was applied to project the wheat yield using CMIP5 models and considering historical and RCP8.5 experiments. PLS regression in spatial dimension was applied to derive the projections.
- ◇ Wheat yield projections were obtained from dataset of precipitation, maximum and minimum temperatures corresponding to the CMIP5 models, where DTR and SPI are derived from these variables. Projections indicated a wheat yield reduction for the twenty-first century (32 %), which is greater without applying the eQM bias correction. However, after applying the eQM bias correction, the projections were modified, obtaining a decrease about of 8 %. Spread of wheat yield projections is largely due to the uncertainty of projected precipitation. Therefore, with the aim of improving confidence in the wheat yield projections it was decided the search large-scale predictors, the results of which are included in the second article.
- ◇ Results of wheat yield reduction are justified by analysing the evolution of precipitation and DTR projections. CMIP5 models report a trend towards a decrease in precipitation in autumn and spring and an increase in DTR in winter.

7.2.2. Wheat yield in Spain and associated solar radiation patterns

The aim of this study was to find an agro-climate model based on predictors which would decrease the uncertainty of wheat yield projections in Spain.

Hence, large-scale variables were considered and the questions shown in section 5.2 were posited. These questions are answered with the following conclusions:

- ◇ Wheat yield data were classified using provincial data and applying K-mean cluster analysis, which identified two regions with different variability.
- ◇ PLS was applied to different large-scale variables such as sea level pressure (MSL), geopotential height at 500 hPa (Z500), zonal wind at 250 hPa (U250), sea surface temperature (SST) and surface solar radiation (SSRD). The empirical model selects SSRD for the different phases of wheat growth from sowing to maturity. Hence, SSRD has an influence on the three seasons of autumn, winter and spring.
- ◇ The empirical agro-climate model based on SSRD collects the effects of other large-scale variables, for example Z500, U250, SST over the Pacific in spring and SST over the North Atlantic area in winter. In addition, this model introduces the effects of teleconnection patterns: SSRD in autumn is associated with the AMO, SSRD in winter with the NAO and EA and SSRD in spring with SCAND patterns.
- ◇ The SSRD model shows greater field significance to observed wheat yield than the model based on SPI and DTR. The estimations of wheat yield obtained by the SSRD model are significant for 71 % of the provinces as opposed to 65 % for the model based on SPI and DTR. Furthermore, the modes of SSRD include the effects of precipitation and temperatures as they are negatively associated with SPI in autumn and spring and positively associated with DTR in winter.
- ◇ Projections of wheat yield were obtained using the simulated SSRD from CMIP5 models and applying the PLS method in the spatial dimension. Results predict a reduction of about 6 % and 8 % with respect to mean wheat yield before applying eQM, and around 13 % after the bias correction by eQM.
- ◇ In this study it was found that the uncertainty of the projections of the empirical model based on SSRD decreases with respect to the empirical models based on SPI and DTR. To quantify the trend, uncertainty was obtained from the contribution of the forced variability with respect to the trend associated with internal variability of the different models.

7.2. Specific conclusions

Results highlight that the forced trend due to climate change is less uncertain in the case of the model based on predictors of large-scale with respect to regional scale predictors.

- ◇ Decreased wheat yield was justified with the SSRD projections from CMIP5 model for the twenty-first century, which show an increasing trend.
- ◇ Empirical models obtained from observations could present limitations for future climate conditions. Hence, was decided to use process-based models, the results of which are included in the third article.

7.2.3. Assessing GLAM-wheat simulation to estimate variability and projected trend of wheat yield in Spain

The aim of this study was to assess the variability of wheat yield in Spain simulated with the process-based model GLAM. Therefore, the main conclusions that respond to the issues raised in section 5.3 are the following:

- ◇ Using correlation coefficients and Root Mean Square Error, GLAM simulates wheat yield variability for large areas, at the 95 % confidence level (for example, for the two regions in Spain that cluster the wheat variability). However, for individual provinces, after applying the eQM bias correction, GLAM characterizes wheat significantly in 56 % of the surface area.
- ◇ The assessment of GLAM on the basis of the influence of climate variables indicates that GLAM is able to capture the seasonal climate variability: higher (lower) response to SSRD (SPI) in spring; low (high) response to SSRD (DTR) in winter; and practically insignificant response to SPI and SSRD in autumn.
- ◇ Greater differences between GLAM simulations and observations were observed for ENSO event years. On one hand, it was found that El Niño years cause a reduction in wheat yield. Furthermore, GLAM shows a weaker response to teleconnection indices than the observed wheat yield.
- ◇ The effects of ENSO events on wheat yields can be explained because the

ENSO induces anomalies in the climate variables, and GLAM may not capture the intensity effects of extreme events on wheat.

- ◇ Results suggest combining the empirical and process-based models to include the influence of climate drivers and the effects of teleconnections indices.
- ◇ GLAM was combined with the empirical model based on SSRD. Results show substantial improvement in the significance of the spatial and temporal correspondence because the hybrid model accounts for more variance (83 %) than GLAM (52 %). Spatially the performance of the hybrid model is better because the significance of the pattern correlation is 89 % as opposed to 56 % from GLAM.
- ◇ Different models were applied to project wheat yield under climate change conditions using CMIP5 models. All the projections show a decrease in wheat yield, of about 42 % for GLAM and 25 % for the hybrid model across the 21st century.
- ◇ All models show a decrease in wheat yield, with lower uncertainty for GLAM and the hybrid model. The trend uncertainty was quantified, obtaining a measure of the signal-to-noise ratio (SNR). A signal of -3.8 was obtained for GLAM and one of -2.9 for the hybrid model.
- ◇ Decreased wheat yield due to the effects of climate change was justified by obtaining the projections of climate variables that affect wheat variability. SSRD and DTR provide an increasing trend and precipitation shows a decreasing trend.

7.3. Future works

The initial perspectives and approaches planned were modified and adapted based on the results obtained and emerging issues. After this thesis some questions still remain and possible lines of research have opened for future research. Some of the possible lines of future work are summarized below:

- ◇ Assessment of the models obtained in this thesis using seasonal predictions to provide a service to the agricultural sector. The agricultural

7.3. Future works

sector needs forecast products for decision-making, planting, harvesting, water management, selecting of crop type, etc. Furthermore, seasonal meteorological predictions have a sub-seasonal and seasonal data base (Vitart et al. 2017) for operational applicability, whose objective is to provide forecasts that can range from 2 weeks to 12 months for predicting extreme events or other events, which may have a social impact. Hence, a useful climate service for agriculture would produce crop yield estimations by combining a multi-model ensemble of seasonal forecasts with crops models. Therefore, using the agro-climate models obtained in this doctoral thesis, along with seasonal and sub-seasonal climate predictions, wheat yields can be predicted, as well as the effects of climate change on yields. Likewise, seasonal predictions could be made for other crops of interest.

- ◇ Research into different methods of bias correction and model optimization. In addition, how the different bias corrections affect crop yield predictions and projections should be determined.
- ◇ Apply the methodology used in this dissertation to other crops, such as olives, grapes and citruses to obtain the impact of climate change.
- ◇ In this study, the relationship between wheat yield and teleconnection indices were obtained. It would be interesting to analyze whether these influences are caused by extreme events associated with teleconnections.
- ◇ The EEMD method has been used to filter out the wheat yield trends projected from the individual models and the multi-model. It would be interesting to apply it to extract the variations of other interannual and interdecadal fluctuations in different productions.
- ◇ The effect of CO_2 was not included in this study, although the possible benefits of CO_2 are still under debate. Supit et al. (2012) reported that wheat yield would increase due to the effects of CO_2 , whereas Asseng et al. (2013) and Deryng et al. (2014) reported a negative impact on wheat yields throughout Europe. Considering these results, it would be of interest to project wheat yield in Spain considering CO_2 effects and to compare the results with those obtained in this dissertation.
- ◇ Extending the research about the uncertainty of projections. In this thesis, the uncertainty was determined as a measure of the signal-to-noise

ratio (SNR), which quantifies the contribution of the forced trend and the unforced trend component attributed to internal and structural variability. However, Hawkins and Sutton (2009) report that model uncertainty may be due to radiative forcing because different models simulate minor changes in the climate with the same radiative forcing.

Referencias

Referencias



Referencias

- Abdi H (2010) Partial least squares regression, projection on latent structure regression (pls regression). *WIREs Comput Stat*:1–10. doi:10.1002/wics.051
- AEMet (2017) Agencia Estatal de Meteorología. El Año 2016 muy cálido y húmedo. http://www.aemet.es/es/noticias/2017/01/2016_muy_calido_humedo
- Arya SP (1988) *Introduction to Micrometeorology*. Academic Press, San Diego, CA, 307pp
- Asseng S, Ewert F, Rosenzweig C, Jones JW, Hatfield JL, Ruane AC, Boote KJ, Thorburn PJ, Rotter RP, Cammarano D, Brisson N, Basso B, Martre P, Aggarwal PK, Angulo C, Bertuzzi P, Biernath C, Challinor AJ, Doltra J, Gayler S, Goldberg R, Grant R, Heng L, Hooker J, Hunt LA, Ingwersen J, Izaurrealde RC, Kersebaum KC, Muller C, Kumar SN, Nendel C, O’Leary G, Olesen JE, Osborne TM, Palosuo T, Priesack E, Ripoche D, Semenov MA, Shcherbak I, Steduto P, Stockle C, Stratonovitch P, Streck T, Supit I, Tao F, Travasso M, Waha K, Wallach D, White JW, Williams JR, Wolf J (2013) Uncertainty in simulating wheat yields under climate change. *Nat Clim Chang* 3(9):827–832. doi:10.1038/nclimate1916
- Atkinson MD, Kettlewell PS, Hollins PD, Stephenson DB, Hardwick NV (2005) Summer climate mediates UK wheat quality response to winter North Atlantic Oscillation. *Agricultural and Forest Meteorology* 130(1-2): 27-37. doi: 10.1016/j.agrformet.2005.02.002
- Auffhammer M, Schlenker W (2014) Empirical studies on agricultural impacts and adaptation. *Energy Economics*, 46: 555-561
- Azam-Ali SN (1984) Environmental and physiological control of transpiration by groundnut crops. *Agr. Forest Meteorol.*, 33, 129-140
- Baker NC, Taylor PC (2016) A framework for evaluating climate model performance metrics. *J. Clim.* 29(5): 1773–1782, doi: 10.1175/jcli-d-15-0114.1
- Baloch UK (1999) *WHEAT: Post-harvest Operations*. Pakistan Agricultural Research Council (PARC). Edited by AGSI/FAO: Danilo Mejia (Technical), Beverly Lewis (Language&Style)
- Barley KP (1970) The configuration of the root system in relation to nutrient uptake. *Adv. Agron.*, 22, 159-201
- Barnston AG, Livezey RE (1987) Classification, seasonality and persistence of low-frequency atmospheric circulation patterns. *Mon Weather Rev* 115(6): 1083–1126
- Belderok RB, Mesdag H, Donner DA (2000) *Bread-Making Quality of Wheat*,

- Springer. p. 3, ISBN 0-7923-6383-3
- Ben-Ari T, Adrian J, Klein T, Calanca P, Van der Velde M, Makowski D (2016) Identifying indicators for extreme wheat and maize yield losses. *Agricultural and Forest Meteorology*, 220: 130-140
- Benjamini Y, Hochberg Y (1995) Controlling the False Discovery Rate: A Practical and Powerful Approach to Multiple Testing. *Journal of the Royal Statistical Society, Series B* 57, 289–300
- Berg SO (1947) Is the degree of grittiness of wheat flour mainly a varietal character? *Cereal chem.* 24:27 4-283
- Bergamaschi H, da Costa SMS, Wheeler TR, Challinor AJ (2013) Simulating maize yield in sub-tropical conditions of southern Brazil using GLAM model. *Pesquisa Agropecuária Brasileira*, 48(2):132–140
- Bergamaschi H, Wheeler TR, Challinor AJ, Comiran F, Heckler BMM (2007) Maize yield and rainfall on different spatial and temporal scales in Southern Brazil. *Pesquisa Agropecuária Brasileira*, 42:603–613
- Bitz CM, Shell KM, Gent PR, Bailey DA, Danabasoglu G, Armour KC, Holland MM, Kiehl JT (2012) Climate sensitivity of the Community Climate System Model, version 4. *Journal of Climate* 25(9):3053-3070
- Brisson N, Gary C, Justes E, Roche R, Mary B, Ripoche D, Zimmer D, Sierra J, Bertuzzi P, Burger P, Bussi ere F, Cabidoche YM, Cellier P, Debaeke P, Gaudill ere JP, H enault C, Maraux V, Seguin B, Sinoquet H (2003) An overview of the crop model STICS. *Eur. J. Agron.*, 18, 309-332
- Brown I (2013) Influence of seasonal weather and climate variability on crop yields in Scotland. *Int J Biometeorol* 57(4):605–614. doi:10.1007/s00484-012-0588-9
- Cantelaube P, Terres JM, Doblas-Reyes FJ (2004) Influence of climate variability on European agriculture - analysis of winter wheat production. *Climate Research*, 27(2): 135-144
- Cao W, Moss DN (1997) Modeling phasic development in wheat: A conceptual integration of physiological components. *J. Agric. Sci.*, 129, 163-172
- Capa-Morocho M, Rodriguez-Fonseca B, Ruiz-Ramos M (2016) El Ni o influence on potential maize yield in Iberian Peninsula. *International Journal of Climatology*, 36(3): 1313-1330. Doi: 10.1002/joc.4426
- Capel Molina JJ (2000) El clima en la pen nsula Ib rica. Barcelona. Ariel 281 pgs
- Capparelli V, Franzke C, Vecchio A, Freeman MP, Watkins NW, Carbone V (2013) A spatiotemporal analysis of U.S. station temperature trends over

Referencias

- the last century, *J. Geophys. Res. Atmos.*, 118, 7427–7434, doi:10.1002/jgrd.50551
- Carmona A, Poveda G (2012) Aplicación de la transformada de hilbert-huang en la detección de modos de variabilidad hidroclimática en Colombia. *Dyna rev.fac.nac.minas* [online]. vol.79, n.175 [cited 2016-10-16], pp.72-80. ISSN 0012-7353
- Casanueva A, Rodríguez-Puebla C, Frias MD, González-Reviriego N (2014) Variability of extreme precipitation over Europe and its relationships with teleconnection patterns, *Hydrol. Earth Syst. Sci.*, 18, 709-725, doi:10.5194/hess-18-709-2014
- Castro M, Martín-Vide J, Alonso S (2005) The climate of Spain: Past, present and scenarios for the 21st century. A preliminary assessment of the impacts in Spain due to the effects of climate change, J. M. Moreno, Ed., Ministry of the Environment ECCE Project Final Rep., 1–62
- CEAS (2013) Consejería de Agricultura y Ganadería, Junta de Castilla y León. Evolución de las cuentas económicas de la agricultura años 2010, 2011 y 2012 (1 febrero 2013)
- Ceglar A, Toreti A, Lecerf R, Van der Velde M, Dentener F (2016) Impact of meteorological drivers on regional inter-annual crop yield variability in France. *Agricultural and Forest Meteorology*, 216: 58-67. doi:/10.1016/j.agrformet.2015.10.004
- Ceglar A, Turco M, Toreti A, Doblas-Reyes FJ (2017) Linking crop yield anomalies to large-scale atmospheric circulation in Europe. *Agricultural and Forest Meteorology* 240-241, 35-45. doi: 10.1016/j.agrformet.2017.03.019
- Cendrero Orestes (1938) *Nociones de historia natural* (séptima edición). París
- Challinor AJ, Simelton ES, Fraser ED, Hemming D, Collins M (2010) Increased crop failure due to climate change: assessing adaptation options using models and socio-economic data for wheat in China. *Environmental Research Letters*, 5(3)
- Challinor AJ, Slingo JM, Wheeler TR, Doblas-Reyes FJ (2005b) Probabilistic simulations of crop yield over western India using the DEMETER seasonal hindcast ensembles. *Tellus A*, 57(3):498–512
- Challinor AJ, Watson J, Lobell DB, Howden SM, Smith DR, Chhetri N (2014) A meta-analysis of crop yield under climate change and adaptation. *Nat. Clim.Change* 4, 287–291
- Challinor AJ, Wheeler TR, Slingo JM, Craufurd PQ, Grimes DIF (2004) Design and optimisation of a large-area process-based model for annual crops.

- Agricultural and Forest Meteorology, 124: 99–120
- Challinor AJ, Wheeler TR, Slingo JM, Craufurd PQ, Grimes DIF (2005a) Simulation of crop yields using the ERA40 re-analysis: limits to skill and non-stationarity in weather–yield relationships. *Journal of Applied Meteorology*, 44(4):516–531
- Challinor AJ, Wheeler TR, Slingo JM, Hemming D (2005c) Quantification of physical and biological uncertainty in the simulation of the yield of a tropical crop using present-day and doubled CO₂ climates. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 360(1463): 2085–2094
- Challinor AJ, Wheeler TR (2008) Crop yield reduction in the tropics under climate change: processes and uncertainties. *Agricultural and Forest Meteorology*, 148(3):343–356
- Changnon SA, Hollinger SE (2003) Problems in estimating impacts of future climate change on Midwestern corn yields. *Clim. Change*, 58, 109–118
- Chee-Kiat T (2006) Application of satellite-based rainfall estimates to crop yield forecasting in Africa. PhD thesis, University of Reading, Reading, UK
- Chen C, Baethgen WE, Robertson A (2013) Contributions of individual variation in temperature, solar radiation and precipitation to crop yield in the North China Plain, 1961–2003. *Climatic Change*, 116(3–4): 767–788. doi: 10.1007/s10584-012-0509-2
- Chen C, Zhou GS, Pang YM (2015) Impacts of climate change on maize and winter wheat yields in China from 1961 to 2010 based on provincial data. *J Agric Sci* 153(5):825–836. doi:10.1017/s0021859614001154
- Chmielewski FM, Muller A, Bruns E (2004) Climate changes and trends in phenology of fruit trees and field crops in Germany, 1961–2000. *Agr. Forest Meteorol.*, 121, 69–78
- Choudhury BJ, Idso SB, Reginato RJ (1987) Analysis of an empirical model for soil heat flux under a growing wheat crop for estimating evaporation by an infrared temperature based energy balance equation. *Agric. Forest Meteorol.*, 39, 283–297
- Ciscar JC, Feyen L, Soria A, Lavalle C, Raes F, Perry M, Nemry F, Demirel H, Rozsai M, Dosio A, Donatelli M, Srivastava A, Fumagalli D, Niemeier S, Shrestha S, Ciaian P, Himics M, Van Doorslaer B, Barrios S, Ibáñez N, Forzieri G, Rojas R, Bianchi A, Dowling P, Camia A, Libertà G, San Miguel J, de Rigo D, Caudullo G, Barredo JI, Paci D, Pycroft J, Saveyn

Referencias

- B, Van Regemorter D, Revesz T, Vandyck T, Vrontisi Z, Baranzelli C, Vandecasteele I, Batista e Silva F, Ibarreta D (2014) Climate Impacts in Europe. The JRC PESETA II Project. JRC Scientific and Policy Reports, EUR 26586EN
- CLIVAR (2010) Clima en España: Pasado, Presente y Futuro. Informe de evaluación del cambio climático regional. Editores: Fiz F. Pérez y Roberta Boscolo. Enero 2010
- Colledge S, Conolly J (2007) The origins and spread of domestic plants in Southwest Asia and Europe. University College London Institute of Archaeology Publications. Left Coast Press: Walnut Creek, US
- Collins WJ, Bellouin N, Doutriaux-Boucher M, Gedney N, Halloran P, Hinton T, Hughes J, Jones CD, Joshi M, Liddicoat S, Martin G, O'Connor F, Rae J, Senior C, Sitch S, Totterdell I, Wiltshire A, Woodward S (2011) Development and evaluation of an Earth-System model-HadGEM2. Geoscientific Model Development Discussions 4:1051-1075, doi:10.5194/gmd-4-1051-2011
- Colominas MA, Schlotthauer G, Torres ME (2014) Improved complete ensemble EEMD: A suitable tool for biomedical signal processing. Biomedical Signal Processing and Control 14:19–29, doi: 10.1016/j.bspc.2014.06.009
- Compo GP, Whitaker JS, Sardeshmukh PD, Matsui N, Allan RJ, Yin X, Gleason BE, Vose RS, Rutledge G, Bessemoulin P, Bronnimann S, Brunet M, Crouthamel RI, Grant AN, Groisman PY, Jones PD, Kruk MC, Kruger AC, Marshall GJ, Maugeri M, Mok HY, Nordli O, Ross TF, Trigo RM, Wang XL, Woodruff SD, Worley SJ (2011) The Twentieth Century Reanalysis Project. Quarterly Journal of the Royal Meteorological Society 137(654):1-28
- Conradt T, Gornott C, Wechsung F (2016) Extending and improving regionalized winter wheat and silage maize yield regression models for Germany: Enhancing the predictive skill by panel definition through cluster analysis. Agricultural and Forest Meteorology 216: 68-81. doi: 10.1016/j.agrformet.2015.10.003
- Cooper PJM, Gregory PJ, Tully D, Harris HC (1987) Improving water use efficiency of annual crops in the rainfed farming systems of West Asia and North Africa. Exp. Agr., 23, 113-158
- Coumou D, Rahmstorf S (2012) A decade of weather extremes. Nat Clim Chang 2(7):491–496. doi:10.1038/nclimate1452
- Dalla Marta A, Grifoni D, Mancini M, Zipoli G, Orlandini S (2011) The in-

- fluence of climate on durum wheat quality in Tuscany, Central Italy. *International Journal of Biometeorology* 55(1): 87-96. doi: 10.1007/s00484-010-0310-8
- Davidian M, Giltinan DM (1995) *Nonlinear Mixed Effects Models for Repeated Measurement Data*. Chapman and Hall
- de Jong S (1993) SIMPLS: An alternative approach to partial least squares regression. *Chemometrics and Intelligent Laboratory Systems* 18(3):251-263
- de Wit CT (1958) *Transpiration and crop yields*. Agricultural Research Reports 64.6., Wageningen, 88 pp
- Decker WL (1994) Developments in agricultural meteorology as a guide to its potential for the twenty-first century, *Agr. Forest Meteorol.*, 69, 9-25
- Dee DP, Uppala SM, Simmons AJ, Berrisford P, Poli P, Kobayashi S, Andrae U, Balmaseda MA, Balsamo G, Bauer P, Bechtold P, Beljaars ACM, van de Berg L, Bidlot J, Bormann N, Delsol C, Dragani R, Fuentes M, Geer AJ, Haimberger L, Healy SB, Hersbach H, Holm EV, Isaksen L, Kallberg P, Kohler M, Matricardi M, McNally AP, Monge-Sanz BM, Morcrette JJ, Park BK, Peubey C, de Rosnay P, Tavolato C, Thepaut JN, Vitart F (2011) The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Q. J. R. Meteorol. Soc.* 137(656): 553–597, doi: 10.1002/qj.828
- Déqué M (2007) Frequency of precipitation and temperature extremes over France in an anthropogenic scenario: Model results and statistical correction according to observed values. *Global and Planetary Change*, 57 (12), 1626, doi:10.1016/j.gloplacha.2006.11.030
- Deryng D, Conway D, Ramankutty N, Price J, Warren R (2014) Global crop yield response to extreme heat stress under multiple climate change futures. *Environ Res Lett* 9(3). doi:10.1088/1748-9326/9/3/034011
- Deser C, Phillips AS, Alexander MA, Smoliak BV (2014) Projecting North American Climate over the Next 50 Years: Uncertainty due to Internal Variability. *Journal of Climate*, 27(6): 2271-2296. doi: 10.1175/JCLI-D-13-00451.1
- Deser C, Phillips A, Bourdette V, Teng HY (2012) Uncertainty in climate change projections: the role of internal variability. *Climate Dynamics*, 38(3-4): 527-546
- Diamond J (1997) *Guns, Germs and Steel: A short history of everybody for the last 13,000 years*. Viking UK Random House. ISBN 0-09-930278-0

Referencias

- Duncan WG, Hesketh JD (1968) Net photosynthetic rates, relative leaf growth rates, and leaf numbers of 22 races of maize grown at eight temperatures. *Crop Science*, 8(6):670–674
- Dunne JP, John JG, Shevliakova E, Stouffer RJ, Krasting JP, Malyshev SL, Milly PCD, Sentman LT, Adcroft AJ, Cooke W, Dunne KA, Griffies SM, Hallberg RW, Harrison MJ, Levy H, Wittenberg AT, Phillips PJ, Zadeh N (2013) GFDL's ESM2 global coupled climate-carbon Earth System Models. Part II: carbon system formulation and baseline simulation characteristics. *Journal of Climate* 26(7):2247-2267
- Durbin J, Watson GS (1950) Testing for Serial Correlation in Least Squares Regression, I. *Biometrika*. 37 (3–4): 409–428. doi:10.1093/biomet/37.3-4.409. JSTOR 2332391
- Durbin J, Watson GS (1951) Testing for Serial Correlation in Least Squares Regression, II. *Biometrika*. 38 (1–2): 159–179. doi:10.1093/biomet/38.1-2.159. JSTOR 2332325
- Echeverría JC, Crowe JA, Woolfson, MS, Hayes-Gill BR (2001) Application of empirical mode decomposition to heart rate variability analysis. 39 (4): 471-479. doi:10.1007/BF02345370
- Edwards DC, McKee TB (1997) Characteristics of 20th century drought in the United states at multiple timescales. Colorado State University: Fort Collins. Climatology Report No. 92-7
- Efron B (1979) Bootstrap methods: another look at the jackknife. *Annals of Statistics* 7(1):1-26
- Eitzinger J, Thaler S, Schmid E, Strauss F, Ferrise R, Moriondo M, Bindi M, Palosuo T, Rotter R, Kersebaum KC, Olesen JE, Patil RH, Saylan L, Caldag B, Caylak O (2013) Sensitivities of crop models to extreme weather conditions during flowering period demonstrated for maize and winter wheat in Austria. *J Agric Sci* 151(6):813–835. doi:10.1017/s0021859612000779
- Escobar PR (1972) El cultivo del trigo y su relación con el clima. Quito, Ecuador: INIAP, Estación Experimental Santa Catalina, Programa de Cereales. (Boletín Divulgativo no. 1)
- Fan J, Yao Q (2005) Nonlinear time series: nonparametric and parametric methods. Springer, New York
- FAO (2014, 2016) Food agriculture organization of the united nations (FAO), <http://faostat3.fao.org/compare/E>
- Feldman M, Kislev Mordechai E (2007) Domestication of emmer wheat and

- evolution of free-threshing tetraploid wheat. *Israel Journal of Plant Sciences*, Volume 55, Number 3 - 4 / 2007, pp. 207 – 221
- Feng J, Wu Z, Liu G (2014) Fast multidimensional ensemble empirical mode decomposition using a data compression technique. *J Clim* 27(10):3492–3504. doi:10.1175/jcli-d-13-00746.1
- Fisher RA (1915) Frequency distribution of the values of the correlation coefficient in samples of an indefinitely large population. *Biometrika* Trust. 10 (4): 507–521. doi:10.2307/2331838. JSTOR 2331838
- Fischer RA (1980) Influence of water stress on crop yield in semiarid regions. *Adaptation of Plants to Water and High Temperature Stress*, N.C. Turner and P. Kramer, Eds., Willey and Son, New York, 323-340
- Flandrin P, Rilling G, Goncalves P (2004) Empirical mode decomposition as a filter bank. *IEEE Signal Process Lett* 11(2):112–114. doi:10.1109/lsp.2003.821662
- Flato G, Marotzke J, Abiodun B, Braconnot P, Chou SC, Collins W, Cox P, Driouech F, Emori S, Eyring V, Forest C, Gleckler P, Guilyardi E, Jakob C, Kattsov V, Reason C, Rummukainen M (2013) Evaluation of climate models. In *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. T.F. Stocker, D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Doschung, A. Nauels, Y. Xia, V. Bex, and P.M. Midgley, Eds. Cambridge University Press, 741-882, doi:10.1017/CBO9781107415324.020
- Fogli PG, Manzini E, Vichi M, Alessandri A, Patara L, Gualdi S, Scoccimarro E, Masina S, Navarra A (2009) INGV-CMCC Carbon (ICC): a carbon cycle Earth System Model. *CMCC Research Paper* 61
- Font Tullot L (2000) *Climatología de España y Portugal*. Universidad de Salamanca. Salamanca
- Franzke C (2009) Multi-scale analysis of teleconnection indices: climate noise and nonlinear trend analysis, *Nonlin. Processes Geophys.*, 16, 65-76, doi:10.5194 npg-16-65-2009
- Franzke C (2015) Local trend disparities of european minimum and maximum temperature extremes. *Geophys Res Lett* (in press). doi:10.1002/2015GL065011
- Friend DJC, Helson VA, Fisher JE (1962) Leaf growth in Marquis wheat, as regulated by temperature, light intensity, and daylength. *Can. J. Bot.*, 40, 1299-1311

Referencias

- Fuller DO, Ottke C (2002) Land cover, rainfall and land-surface albedo in West Africa. *Climatic Change*, 54(1):181–204
- Gabor D (1946) Theory of communication. *J Inst Electr Eng* 93:429–457
- Gajri PR, Prihar SS (1985) Rooting, water use and yield relations in wheat on loamy sand and sandy loam soils. *Field Crops Res.*, 12, 115-132
- Gamo M (1999) Classification of arid regions by climate and vegetation. *J. Arid Land Studies*, 1, 9-17
- García del Moral LF, Rharrabti Y, Villegas D, Royo C (2003) Evaluation of grain yield and its components in durum wheat under Mediterranean conditions: An ontogenic approach. *Agron. J.*, 95, 266-274
- Geladi P, Kowalski BR (1986) Partial least-squares regression: a tutorial. *Analytica Chimica Acta* 185:1-17
- Gent PR, Danabasoglu G, Donner LJ, Holland MM, Hunke EC, Jayne SR, Lawrence DM, Neale RB, Rasch PJ, Vertenstein M, Worley PH, Yang ZL, Zhang MH (2011) The Community Climate System Model version 4. *Journal of Climate* 24(19):4973-4991
- Gervois S, Ciais P, de Noblet-Ducoudre N, Brisson N, Vuichard N, Viovy N (2008) Carbon and water balance of european croplands throughout the 20th century. *Global Biogeochemical Cycles*, 22, GB2022, doi: 10.1029/2007GB003018
- Gilbert RO (1987) *Statistical methods for environmental pollution monitoring*, John Wiley & Sons, New York, 320 pp
- Gimeno L, Ribera P, Iglesias R, de la Torre L, Garcia R, Hernandez E (2002) Identification of empirical relationships between indices of ENSO and NAO and agricultural yields in Spain. *Climate Research* 21(2): 165-172. doi:10.3354/cr021165
- GLAM-R2 (2009) The General Large Area Model for annual crops (GLAM). Release version 2. www.see.leeds.ac.uk/redmine/public/projects/glam
- Godwin DC, Ritchie JT, Singh U, Hunt L (1989) *A User's Guide to CERES-Wheat v2.1*. International Fertilizer Development Centre, Muscle Shoals, AL
- Gonzalez-Reviriego N, Rodriguez-Puebla C, Rodriguez-Fonseca B (2015) Evaluation of observed and simulated teleconnections over the Euro-Atlantic region on the basis of partial least squares regression. *Climate Dynamics*, 44(11-12): 2989-3014. doi: 10.1007/s00382-014-2367-2
- Gornall J, Betts R, Burke E, Clark R, Camp J, Willett K, Wiltshire A (2010) Implications of climate change for agricultural productivity in the early

- twenty-first century. *Philosophical Transactions of the Royal Society B-Biological Sciences*, 365(1554): 2973-2989; DOI: 10.1098/rstb.2010.0158
- Gouache D, Bouchon AS, Jouanneau E, Le Bris X (2015) Agrometeorological analysis and prediction of wheat yield at the departmental level in France. *Agric*
- Greatrex H (2012) The application of seasonal rainfall forecasts and satellite rainfall estimates to seasonal crop yield forecasting for Africa. PhD thesis, The University of Reading, Department of Meteorology, Reading, UK
- Grundas ST (2003) Chapter: Wheat: The Crop, in *Encyclopedia of Food Sciences and Nutrition* p6130, 2003; Elsevier Science Ltd
- Guan BT (2014) Ensemble empirical mode decomposition for analyzing phenological responses to warming. *Agric For Meteorol* 194:1–7. doi: 10.1016/j.agrformet.2014.03.010
- Guerrero A (1999) *Cultivos herbáceos extensivos*. Mundi-Prensa. Madrid. 831 p
- Hansen JW, Challinor AJ, Ines A, Wheeler T, Moron V (2006) Translating climate forecasts into agricultural terms: advances and challenges. *Climate Research*, 33(1):27–41
- Hansen JW, Potgieter A, Tippet MK (2004) Using a general circulation model to forecast regional wheat yields in northeast Australia. *Agricultural and Forest Meteorology* 127:77-92
- Härdle W (1990) *Applied nonparametric regression*. Cambridge University Press, Cambridge
- Hay RKM, Porter JR (2006) *The physiology of crop yield*. Blackwell Publishing Ltd: Oxford, UK. ISBN: 978-1-4051-0859-1
- Haylock MR, Hofstra N, Tank A, Klok EJ, Jones PD, New M (2008) A European daily high-resolution gridded data set of surface temperature and precipitation for 1950–2006. *J Geophys Res – Atmos* 113(D20):55–76. doi:10.1029/2008jd010201. D20119
- Hawkins E, Osborne TM, Ho CK, Challinor AJ (2013) Calibration and bias correction of climate projections for crop modelling: An idealised case study over Europe. *Agric For Meteorol* 170:19–31. doi: 10.1016/j.agrformet.2012.04.007
- Hawkins E, Sutton R (2009) The Potential to Narrow Uncertainty in Regional Climate Predictions. *Bulletin of the American Meteorological Society*, 90(8): 1095-1107. doi:10.1175/2009BAMS2607.1
- Herrera S, Gutierrez JM, Ancell R, Pons MR, Frias MD, Fernandez J (2012)

Referencias

- Development and analysis of a 50-year high-resolution daily gridded precipitation dataset over Spain (spain02). *Int J Climatol* 32(1):74–85. doi: 10.1002/joc.2256
- Hernández-Barrera S, Rodríguez-Puebla C (2017) Wheat yield in Spain and associated solar radiation patterns. *International Journal of Climatology*, submitted, doi: 10.1002/joc.4975
- Hernández-Barrera S, Rodríguez-Puebla C, Challinor AJ (2016) Effects of diurnal temperature range and drought on wheat yield in Spain. *Theor Appl Climatol*, 129(1): 503–519, doi: 10.1007/s00704-016-1779-9
- Hogan CM (2013) Wheat. *Encyclopedia of Earth*. National Council of Science and the Environment, Washington DC ed. P. Saundry
- Huang B, Banzon VF, Freeman E, Lawrimore J, Liu W, Peterson TC, Smith TM, Thorne PW, Woodruff SD, Zhang HM (2015) Extended Reconstructed Sea Surface Temperature Version 4 (ERSST.v4). Part I: Upgrades and Intercomparisons. *Journal of Climate*, 28(3): 911–930, doi:10.1175/JCLI-D-14-00006.1
- Huang NE, Shen Z, Long SR (1999) A new view of nonlinear water waves. The Hilbert spectrum, *Annu. Rev. Fluid Mech.*, 31,417–457, doi: 10.1146/annurev.fluid.31.1.417
- Huang NE, Shen Z, Long SR, Wu MC, Shih HH, Zheng Q, Yen N-C, Tung CC, Liu HH (1998) The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis. *Proc. R. Soc. London, Ser. A*, 454,903–993
- Huang NE, Wu Z (2008) A review on Hilbert–Huang transform: the method and its applications on geophysical studies. *Rev Geophys* 46: RG2006. doi:10.1029/2007RG000228
- Hurrell JW, Holland MM, Gent PR, Ghan S, Kay JE, Kushner PJ, Lamarque JF, Large WG, Lawrence D, Lindsay K, Lipscomb WH, Long MC, Mahowald N, Marsh DR, Neale RB, Rasch P, Vavrus S, Vertenstein M, Bader D, Collins WD, Hack JJ, Kiehl J, Marshall S (2013) The Community Earth System Model: a framework for collaborative research. *Bulletin of the American Meteorological Society* 94(9):1339–1360
- Hutchinson MF (1993) On thin plate splines and kriging, in *Computing in Science and Statistics*, edited by M. E. Tarter and M. D. Lock, pp. 55–62, Univ. of Calif., Berkeley, Calif
- Iglesias A, Garrote L, Quiroga S, Moneo M (2012) From climate change impacts to the development of adaptation strategies: challenges for agriculture in

- Europe. *Climatic Change*, 112:143–168, DOI: 10.1007/s10584-011-0344-x
- Iglesias A, Quiroga S (2007) Measuring the risk of climate variability to cereal production at five sites in Spain. *Clim Res* 34(1):47–57
- Iglesias A, Rosenzweig C, Pereira D (2000) Agricultural impacts of climate change in Spain: developing tools for a spatial analysis. *Global Environmental Change-Human and Policy Dimensions* 10(1): 69-80
- IPCC (2013) *Climate Change 2013: the physical science basis*. In: Stocker TF, Qin D, Plattner G-K, Tignor M, Allen SK, Boschung J, Nauels A, Xia Y, Bex V, Midgley PM (eds) *Contribution of working group I to the fifth assessment report of the intergovernmental panel on climate change*. Cambridge University Press, Cambridge
- IPCC (2014) *Climate Change 2014: impacts, adaptation, and vulnerability. part a: global and sectoral aspects*. In: Field CB, Barros VR, Dokken DJ, Mach KJ, Mastrandrea MD, Bilir TE, Chatterjee M, Ebi KL, Estrada YO, Genova RC, Girma B, Kissel ES, Levy AN, MacCracken S, Mastrandrea PR, White LL (eds) *Contribution of working group II to the fifth assessment report of the intergovernmental panel on climate change*. Cambridge University Press, Cambridge
- Iversen T, Bentsen M, Bethke I, Debernard JB, Kirkevåg A, Seland O, Drange H, Kristjansson JE, Medhaug I, Sand M, Seierstad IA (2013) The Norwegian Earth System Model, NorESM1-M - Part 2: climate response and scenario projections. *Geoscientific Model Development* 6(2):389-415
- Jamieson PD, Semenov MA, Brooking IR, Francis GS (1998) Sirius: a mechanistic model of wheat response to environmental variation. *European Journal of Agronomy*, 8: 161-179
- Jarlan L, Abaoui J, Duchemin B, Ouldbba A, Toure YM, Khabba S, Le Page M, Balaghi R, Mokssit A, Chehbouni G (2014) Linkages between common wheat yields and climate in Morocco (1982-2008). *International Journal of Biometeorology* 58(7): 1489-502. doi: 10.1007/s00484-013-0753-9
- Ji F, Wu Z, Huang J, Chassignet EP (2014) Evolution of land surface air temperature trend. *Nat Clim Chang* 4(6):462–466. doi:10.1038/nclimate2223
- Jones JW, Hoogenboom G, Porter CH, Boote KJ, Batchelor WD, Hunt LA, Wilkens PW, Singh U, Gijsman AJ, Ritchie JT (2003) The DSSAT cropping system model. *Europ. J. Agron.*, 18, 235-265
- Jungclauss JH, Fischer N, Haak H, Lohmann K, Marotzke J, Matei D, Mikolajewicz U, Notz D, von Storch JS (2013) Characteristics of the ocean simulations in the Max Planck Institute Ocean Model (MPIOM) the ocean

Referencias

- component of the MPI-Earth system model. *Journal of Advances in Modeling Earth Systems* 5(2):422-446
- Kalela-Brundin M (1999) Climatic information from tree-rings of *Pinus sylvestris* L. and a reconstruction of summer temperatures back to AD 1500 in Femundsmarka, eastern Norway, using partial least squares regression (PLS) analysis. *Holocene* 9(1):59–77
- Kalnay E, Kanamitsu M, Kistler R, Collins W, Deaven D, Gandin L, Iredell M, Saha S, White G, Woollen J, Zhu Y, Chelliah M, Ebisuzaki W, Higgins W, Janowiak J, Mo KC, Ropelewski C, Wang J, Leetmaa A, Reynolds R, Chelliah M, Ebisuzaki W, Higgins W, Janowiak J, Mo KC, Ropelewski C, Wang J, Jenne R, Joseph D (1996) The NCEP/NCAR 40-year reanalysis project. *Bulletin of the American Meteorological Society* 77(3):437-47
- Keating BA, Carberry PS, Hammer GL, Probert ME, Robertson MJ, Holzwoth D, Huth NI, Hargreaves JNG, Meinke H, Hochman Z, McLean G, Verbug K, Snow V, Dimes JP, Silburn M, Wang E, Brown S, Bristow KL, Asseng S, Chapman S, McCown RL, Freebairn DM, Smith CJ (2003) An overview of APSIM, a model designed for farming systems simulation. *European Journal of Agronomy*, 18:267-288
- Kendall MG (1975) *Rank Correlation Methods*, Charles Griffin & Co. Ltd., London, 202 pp
- Kemp DR, Blacklow WM (1982) The responsiveness to temperature of the extension rates of leaves of wheat growing in the field under different levels of nitrogen fertilizer. *J. Exp. Bot.*, 33, 29-36
- Kent, NL (1983) *Technology of Cereals: An introduction for students of food science and agriculture*. Oxford: Pergamon Press Ltd. ISBN 84-200-0608-4
- Knutti R, Sedlacek J (2013) Robustness and uncertainties in the new CMIP5 climate model projections. *Nat. Clim. Change* 3(4): 369–373, doi: 10.1038/nclimate1716
- Kobayashi C, Iwasaki T (2016) Brewer-Dobson circulation diagnosed from JRA-55. *J. Geophys. Res. Atmos.*, 121, doi: 10.1002/2015JD023476
- Köppen W (1984) Die Wärmezonen der Erde, nach der Dauer der heissen, gemässigten und kalten Zeit und nach der Wirkung der Wärme auf die organische Welt betrachtet. *Meteorologische Zeitschrift*, 1: 215-226
- Kottke M, Grieser J, Beck C, Rudolf B, Rubel F (2006) Die Wärmezonen der Erde, nach der Dauer der heissen, gemässigten und kalten Zeit und nach der Wirkung der Wärme auf die organische Welt betrachte. *World Map of the Köppen-Geiger climate classification updated*. *Meteorologische*

- Zeitschrift, 15(3): 259-263, doi:10.1127/0941-2948/2006/0130
- Kröner N, Kotlarski S, Fischer E, Lüthi D, Zubler E, Schär C (2017) Separating climate change signals into thermodynamic, lapse-rate and circulation effects: theory and application to the European summer climate. *Clim Dyn* (2017) 48: 3425. doi:10.1007/s00382-016-3276-3
- Leng G, Zhang X, Huang M, Asrar GR, Leung R (2016) The role of climate covariability on crop yields in the conterminous United States. *Scientific Reports*, 6:33160,1: 11. doi: 10.1038/srep33160
- Lesk C, Rowhani P, Ramankutty N (2016) Influence of extreme weather disasters on global crop production. *Nature* 529 (7584): 84. doi: 10.1038/nclimate1716
- Li S (2008) Investigating the impacts of climate change on wheat in China. PhD thesis, University of Reading, Reading, UK
- Lindgren F, Geladi P, Wold S (1993) The kernel algorithm for PLS. *Journal of Chemometrics* 7(1):45-59
- Linés A (1970) The Climate of the Iberian Peninsula. In: Landsberg H.E. (ed.). *World Survey of Climatology* Amsterdam Elsevier
- Livezey RE, Chen WY (1983) Statistical field significance and its determination by Monte Carlo techniques. *Mon. Wea. Rev.*, 111, 46–59, doi 10.1175/1520-0493(1983)111<0046:SFS&AID>2.0.CO;2
- Lobell DB (2007) Changes in diurnal temperature range and national cereal yields. *Agric For Meteorol* 145(3–4):229–238. doi: 10.1016/j.agrformet.2007.05.002
- Lobell DB (2013) Errors in climate datasets and their effects on statistical crop models. *Agric For Meteorol* 170:58–66. doi: 10.1016/j.agrformet.2012.05.013
- Lobell DB, Asner GP (2003) Climate and management contributions to recent trends in U.S. agricultural yields. *Science*, 299, 1032
- Lobell DB, Asseng S (2017) Comparing estimates of climate change impacts from process-based and statistical crop models. *Environmental Research Letters* 12(1):015001
- Lobell DB, Burke MB (2010) On the use of statistical models to predict crop yield responses to climate change. *Agric For Meteorol* 150(11):1443–1452. doi: 10.1016/j.agrformet.2010.07.008
- Lobell DB, Gourdji SM (2012) The Influence of Climate Change on Global Crop Productivity. *Plant Physiology*, 160(4): 1686-1697
- Lobell DB, Schlenker W, Costa-Roberts J (2011) Climate trends and global crop production since 1980. *Science* 333, 616–620

Referencias

- Lobell DB, Tebaldi C (2014) Getting caught with our plants down: the risks of a global crop yield slowdown from climate trends in the next two decades. *Environ. Res. Lett.* 9(7): 074003, doi: 10.1088/1748-9326/9/7/074003
- López MA, Chaves B, Florez VJ (2011) Modelos de cultivos y modelos fenológicos. En: Fl.rez R., V.J. (Ed.). *Sustratos, manejo del clima, automatización y control en sistemas de cultivo sin suelo*. Bogotá. Editorial Universidad Nacional de Colombia. pp. 153-177
- Lorber A, Kowalski BR (1988) A note on the use of the partial least-squares method for multivariate calibration. *Applied Spectroscopy* 42(8): 1572-1574
- Lorenzo-Lacruz J, Vicente-Serrano SM, Gonzalez-Hidalgo JC, Lopez- Moreno JI, Cortesi N (2013) Hydrological drought response to meteorological drought in the Iberian peninsula. *Clim Chang* 58(2):117–131. doi:10.3354/cr01177
- Luo Q, Wen L (2015) The role of climatic variables in winter cereal yields: a retrospective analysis. *Int J Biometeorol* 59(2):181–192. doi:10.1007/s00484-014-0834-4
- Mac Key J (2005) Wheat: its concept. Evolution and taxonomy. Royo, C. et al. (eds). *Durum wheat breeding. Current approaches and future strategies*, vol. 1. CRC Press, Boca Raton. Pp: 3-61
- MacQueen J (1967) Some methods for classification and analysis of multivariate observations. In *Proc. 5th Symp. Math. Statist, Prob.* pp. 281–297
- MAGRAMA (2016) *Anuario de Estadística 2015*. Spanish agriculture, food and environment Department. <http://www.magrama.gob.es/es/estadistica/temas/estadisticas-agrarias/>
- Makowski D, Asseng S, Ewert F, Bassu S, Durand JL, Li T, Martre P, Adam M, Aggarwal PK, Angulo C, Baron C, Basso B, Bertuzzi P, Biernath C, Boogaard H, Boote KJ, Bouman B, Bregaglio S, Brisson N, Buis S, Cammarano D, Challinor AJ, Confalonieri R, Conijn JG, Corbeels M, Deryng D, De Sanctis G, Doltra J, Fumoto T, Gaydon D, Gayler S, Goldberg R, Grant RF, Grassini P, Hatfield JL, Hasegawa T, Heng L, Hoek S, Hooker J, Hunt LA, Ingwersen J, Izaurralde RC, Jongschaap REE, Jones JW, Kemanian RA, Kersebaum KC, Kim S-H, Lizaso J, Marcaida III M, Müller C, Nakagawa H, Naresh Kumar S, Nendel C, O’Leary GJ, Olesen JE, Oriol P, Osborne TM, Palosuo T, Pravia MV, Priesack E, Ripoche D, Rosenzweig C, Ruane AC, Ruget F, Sau F, Semenov MA, Shcherbak I, Singh B, Singh U, Soo HK, Steduto P, Stöckle C, Stratonovitch P, Streck T, Supit I, Tang L,

- Tao F, Teixeira EI, Thorburn P, Timlin D, Travasso M, Rötter RP, Waha K, Wallach D, White JW, Wilkens P, Williams JR, Wolf J, Yin X, Yoshida H, Zhang Z, Zhu Y (2015) A statistical analysis of three ensembles of crop model responses to temperature and CO₂ concentration, *Agricultural and Forest Meteorology*, Volumes 214–215, 15 December 2015, Pages 483-493, ISSN 0168-1923, <http://dx.doi.org/10.1016/j.agrformet.2015.09.013>
- Mann HB (1945) Nonparametric Tests Against Trend. *Econometrica: Journal of the Econometric Society* 13(3):245-259
- Martin GM, Bellouin N, Collins WJ, Culverwell ID, Halloran PR, Hardiman SC, Hinton TJ, Jones CD, McDonald RE, McLaren AJ, O'Connor FM, Roberts MJ, Rodríguez JM, Woodward S, Best MJ, Brooks ME, Brown AR, Butchart N, Dearden C, Derbyshire SH, Dharssi I, Doutriaux-Boucher M, Edwards JM, Falloon PD, Gedney N, Gray LJ, Hewitt HT, Hobson M, Huddleston MR, Hughes J, Ineson S, Ingram WJ, James PM, Johns TC, Johnson CE, Jones A, Jones CP, Joshi MM, Keen AB, Liddicoat S, Lock AP, Maidens AV, Manners JC, Milton SF, Rae JGL, Ridley JK, Sellar A, Senior CA, Totterdell IJ, Verhoef A, Vidale PL, Wiltshire A (2011) The HadGEM2 family of Met Office unified model climate configurations. *Geoscientific Model Development* 4(3):723-757
- Martín-Vide J, Olcina J (2001) *Climas y tiempos de España*. Madrid, Alianza Editorial 258 pgs
- Martre P, Wallach D, Asseng S, Ewert F, Jones JW, Rötter RP, Boote KJ, Ruane AC, Thorburn PJ, Cammarano D, Hatfield JL, Rosenzweig C, Aggarwal PK, Angulo C, Basso B, Bertuzzi P, Biernath C, Brisson N, Challinor AJ, Doltra J, Gayler S, Goldberg R, Grant RF, Heng L, Hooker J, Hunt LA, Ingwersen J, Izaurrealde RC, Kersebaum KC, Müller C, Kumar SN, Nendel C, O'leary G, Olesen JE, Osborne TM, Palosuo T, Priesack E, Ripoche D, Semenov MA, Shcherbak I, Steduto P, Stöckle CO, Stratonovitch P, Streck T, Supit I, Tao F, Travasso M, Waha K, White JW, Wolf J (2015) Multimodel ensembles of wheat growth: many models are better than one. *Global Change Biology* 21(2): 911-925. doi: 10.1111/gcb.12768
- McIntosh P, Ash A, Smith M (2005) From Oceans to Farms: The Value of a Novel 170 Statistical Climate Forecast for Agricultural Management. *J. Climate*, 18, 4287-4302
- McIntosh AR, Lobaugh NJ (2004) Partial least squares analysis of neuroimaging data: applications and advances. *Neuroimage*, 23
- McKee TB, Doesken NJ, Kleist J (1993) The relationship of drought frequency

Referencias

- and duration to time scales. Preprints, Eighth Conf. on Applied Climatology, Anaheim, CA, Amer. Meteor. Soc., 179–184
- Meyer WS, Green GC (1980) Water use by wheat and plant indicators of available soil water. *Agron. J.*, 72, 253-257
- Meyer WS, Green GC (1981) Plant indicators of wheat and soybean crop water stress. *Irrigat. Sci.*, 2, 167-176
- Mogenson VO, Jeensen HE, Rab MA (1985) Grain yield, yield components, drought sensitive, and water use efficiency of spring wheat subjected to water stress at various growth stages. *Irrig. Sci.*, 6, 131-140
- Moore FC, Lobell DB (2014) Adaptation potential of European agricultura in response to climate change. *Nat Clim Chang* 4(7):610–614. doi:10.1038/nclimate2228
- Moore FC, Lobell DB (2015) The fingerprint of climate trends on European crop yields. *Proceedings of the National Academy of Sciences of the United States of America*, 112(9): 2670-2675. Doi: 10.1073/pnas.1409606112
- Moss RH, Edmonds JA, Hibbard KA, Manning MR, Rose SK, van Vuuren DP, Carter TR, Emori S, Kainuma M, Kram T, Meehl GA, Mitchell JFB, Nakicenovic N, Riahi K, Smith SJ, Stouffer RJ, Thomson AM, Weyant JP, Wilbanks TJ (2010) The next generation of scenarios for climate change research and assessment. *Nature* 463(7282):747-756
- Musick JT, Jones OR, Stemart BA, Dusek DA (1994) Water–yield relationships for irrigated and dry land wheat in the US southern plains. *Agron. J.*, 86, 980-986
- Naes T, Martens H (1985) Comparison of prediction methods for multicollinear data. *Communications in Statistics-Simulation and Computation* 14(3):545- 576
- Nicholls N (1997) Increased Australian wheat yield due to recent climate trends. *Nature* 387(6632):484–485
- Nicklin K (2013) Seasonal crop yield forecasting in semi-arid West Africa PhD thesis, University of Reading, Reading, UK
- Osborne TM, Lawrence DM, Challinor AJ, Slingo JM, Wheeler TR (2007) Development and assessment of a coupled crop–climate model. *Global Change Biology*, 13(1):169–183
- Osborne T, Rose G, Wheeler T (2013) Variation in the global-scale impacts of climate change on crop productivity due to climate model uncertainty and adaptation. *Agricultural and Forest Meteorology*, 170:183–194
- Oteros J, Garcia-Mozo H, Botey R, Mestre A, Galan C (2015) Variations in

- cereal crop phenology in Spain over the last twenty-six years (1986–2012). *Clim Chang* 130(4):545–558. doi: 10.1007/s10584-015-1363-9
- Otkin J, Mark Shafer M, Svoboda M, Wardlow B, Anderson M, Hain C, Basara J (2015) Facilitating the use of drought early warning information through interactions with agricultural stakeholders. *Bull Am Meteorol Soc* 7:1073–1078. doi: 10.1175/BAMSD-14-00219.1
- Palmeiro FM, Iza M, Barriopedro D, Calvo N, Garcia-Herrera R (2017) The complex behavior of El Niño winter 2015-2016. *Geophysical Research Letters*, 44(6): 2902-2910
- Parker W (2016) Reanalyses and Observations: What’s the Difference? *Bull. Amer. Meteor. Soc.*, 97, 1565–1572 doi: 10.1175/BAMS-D-14-00226.1
- Páscoa P, Gouveia CM, Russo A, Trigo RM (2016) The role of drought on wheat yield inter-annual variability in the Iberian Peninsula from 1929 to 2012. *International Journal of Biometeorology*. DOI 10.1007/s00484-016-1224-x (available online)
- Passioura JB (1983) Roots and drought resistance. *Agric. Water Manage.*, 7, 265-280
- Pinheiro JC, Bates DM (2000) *Mixed-Effects Models in S and S-PLUS*. Springer, New York
- Pirttioja N, Carter TR, Fronzek S, Bindi M, Hoffmann H, Palosuo T, Ruiz-Ramos MR, Tao F, Trnka M, Acutis M, Asseng S, Baranowski P, Basso B, Bodin P, Buis S, Cammarano D, Deligios P, Destain M, Dumont B, Ewert F, Ferrise R, Francois L, Gaiser T, Hlavinka P, Jacquemin I, Kersebaum KC, Kollas C, Krzyszczak J, Lorite IJ, Minet J, Minguez MI, Montesino M, Moriondo M, Mller CC, Nendel IO, Perego A, Rodrguez A, Ruane AC, Ruget F, Sanna M, Semenov MA, Slawinski C, Stratonovitch P, Supit I, Waha K, Wang E, Wu L, Zhao Z, Rötter RP (2011) Temperature and precipitation effects on wheat yield across a European transect: a crop model ensemble analysis using impact response surfaces. *Clim Res* 65:87105. doi:10.3354/cr01322
- Peng S, Huang J, Sheehy JE, Laza RC, Vispèras RM, Zhong X, Centeno GS, Khush GS, Cassman KG (2004) Rice yields decline with higher night temperature from global warming. *Proc. Natl. Acad. Sci. U.S.A.*, 101, 9971-9975
- Podesta G, Letson D, Messina C, Royce F, Ferreyra RA, Jones J, Hansen J, Liovet I, Grondona M, O’Brien JJ (2002) Use of ENSO-related climate information in agricultural decision making in Argentina: a pilot experience.

Referencias

- Agricultural Systems 74(3): 371-392. doi: 10.1016/s0308-521x(02)00046-x
- Priestly CHB, Taylor RJ (1972) On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly Weather Rev.*, 100, 81-92
- Ramirez-Villegas J, Challinor AJ (2012) Assessing relevant climate data for agricultural applications. *Agricultural and Forest Meteorology* 161: 26-45. doi: 10.1016/j.agrformet.2012.03.015
- Ramirez-Villegas J, Koehler AK, Challinor AJ (2015) Assessing uncertainty and complexity in regional-scale crop model simulations. *Eur. J. Agron.* doi: 10.1016/j.eja.2015.11.021
- Rawson HM, Macpherson HG (2001) *Trigo Regado*. Roma, FAO. ISBN 92-5-304488-8
- Riahi K, Rao S, Krey V, Cho C, Chirkov V, Fischer G, Kindermann G, Nakicenovic N, Rafaj P (2011) Rcp 8.5-a scenario of comparatively high greenhouse gas emissions. *Clim Chang* 109(1-2):33- 57. doi: 10.1007/s10584-011-0149-y
- Rienecker MM, Suarez MJ, Gelaro R, Todling R, Bacmeister J, Liu E, Bosilovich MG, Schubert SD, Takacs L, Kim GK, Bloom S, Chen J, Collins D, Conaty A, da Silva A, Gu W, Joiner J, Koster RD, Lucchesi R, Molod A, Owens T, Pawson S, Pegion P, Redder CR, Reichle R, Robertson FR, Ruddick AG, Sienkiewicz M, Woollen J (2011) MERRA: NASA's modern-era retrospective analysis for research and applications. *Journal of Climate* 24(14):3624-3648
- Ritchie JT, Godwin DC, Otter-Nacke S (1988) *CERES-Wheat. A simulation Model of Wheat Growth and Development*. Texas A&M Univ. Press, College Station
- Rodriguez-Puebla C, Ayuso SM, Frias MD, Garcia-Casado LA (2007) Effects of climate variation on winter cereal production in Spain. *Clim Res* 34(3): 223-232
- Rotter R, Ewert F, Palosuo T, Bindi M, Kersebaum K, Olesen J, Trnka M, van Ittersum M, Janssen S, Rivington M, Semenov M, Wallach D, Porter J, Stewart D, Verhagen J, Angulo C, Gaiser T, Nendel C, Martre P, de Wit A (2013) Challenges for agro-ecosystem modelling in climate change risk assessment for major European crops and farming systems. In: *Impacts World 2013 Conference Proceedings*, pp 555-564, DOI doi:10.2312/pik.2013.001
- Rousseeuw PJ (1987) *Silhouettes - a graphical aid to the interpretation and*

- validation of cluster-analysis. *Journal of Computational and Applied Mathematics*, 20: 53-65. doi: 10.1016/0377-0427(87)90125-7
- Royo C (2008) Utilidades de los recursos fitogenéticos en mejora: algunos ejemplos de trigo duro. *Actas: La biodiversidad agrícola. Conservación, Caracterización y Política. I Simposium Internacional de Biodiversidad Agrícola. Mundi-Prensa. Pp: 43-54*
- Rozelle S, Huang J (2000) Transition, development and the supply of wheat in China. *J. Agr. Resour. Econ.*, 44, 543-571
- Ruiz Camacho R (1981) *Cultivo el trigo y la Cebada. Bogotá: Temas de Orientación Agropecuaria. ISSN 0049-3333*
- Ruiz-Ramos M, Sanchez E, Gallardo C, Minguez MI (2011) Impacts of projected maximum temperature extremes for C21 by an ensemble of regional climate models on cereal cropping systems in the Iberian peninsula. *Nat Hazards Earth Syst Sci* 11(12):3275–3291. doi:10.5194/nhess-11-3275-2011
- Sánchez-Lorenzo A, Calbo J, Wild M (2013) Global and diffuse solar radiation in Spain: Building a homogeneous dataset and assessing their trends. *Global and Planetary Change* 100: 343-352. doi: 10.1016/j.gloplacha.2012.11.010
- Schmidt GA, Kelley M, Nazarenko L, Ruedy R, Russell GL, Aleinov I, Bauer M, Bauer SE, Bhat MK, Bleck R, Canuto V, Chen YH, Cheng Y, Clune TL, Del Genio A, de Fainchtein R, Faluvegi G, Hansen JE, Healy RJ, Kiang NY, Koch D, Lacis AA, LeGrande AN, Lerner J, Lo KK, Matthews EE, Menon S, Miller RL, Oinas V, Olosio AO, Perlwitz JP, Puma MJ, Putman WM, Rind D, Romanou A, Sato M, Shindell DT, Sun S, Syed RA, Tausnev N, Tsigaridis K, Unger N, Voulgarakis A, Yao MS, Zhang J (2014) Configuration and assessment of the GISS ModelE2 contributions to the CMIP5 archive. *Journal of Advances in Modeling Earth Systems* 6(1):141-184
- Schulzweida U (2015) *CDO Climate Data Operators, Users guide. Max-Planck-Institut für Meteorologie. Hamburg, Germany. <https://code.zmaw.de/projects/cdo>*
- Sen PK (1968) Estimates of the regression coefficient based on Kendall's tau. *Journal of the American Statistical Association* 63(324):1379-1389
- Shpiler L, Blum A (1991) Heat tolerance to yield and its components in different wheat cultivars. *Euphytica*, 51, 257-263
- Singh U, Ritchie JT, Thornton PK (1991) CERES-CEREAL model for wheat, maize, sorghum, barley, and pearl millet. In: 1991 *Agronomy Abstracts*,

Referencias

- ASA, Madison, WI, pp. 78
- Smith TM, Reynolds RW, Peterson TC, Lawrimore J (2008) Improvements to NOAA's historical merged land-ocean surface temperature analysis (1880-2006). *Journal of Climate* 21(10): 2283-2296. doi: 10.1175/2007jcli2100.1
- Smoliak BV, Wallace JM, Lin P, Fu Q (2015) Dynamical adjustment of the Northern Hemisphere surface air temperature field: methodology and application to observations. *J Clim* 28(4):1613–1629. doi:10.1175/jcli-d-14-00111.1
- Smoliak BV, Wallace JM, Stoelinga MT, Mitchell TP (2010) Application of partial least squares regression to the diagnosis of year-to-year variations in Pacific Northwest snowpack and atlantic hurricanes. *Geophys Res Lett*:37. doi:10.1029/2009gl041478.L03801
- Steiner JL, Smith RCG, Meyer WS, Adeney JA (1985) Water, foliage temperature, and yield of irrigated wheat in southeastern Australia. *Aust. J. Agric. Res.*, 36, 1-11
- Stevens B, Giorgetta M, Esch M, Mauritsen T, Crueger T, Rast S, Salzmann M, Schmidt H, Bader J, Block K, Brokopf R, Fast I, Kinne S, Kornblueh L, Lohmann U, Pincus R, Reichler T, Roeckner E (2013) Atmospheric component of the MPI-M Earth System Model: ECHAM6. *Journal of Advances in Modeling Earth Systems* 5(2):146-172
- Stöckle CO, Donatelli M, Nelson R (2003) CropSyst a cropping system simulation model. *Europ. J. Agron.*, 18, 289-307
- Stöckle CO, Nelson RL (2000) Cropsyst User's Manual (Version 3.0). Biological Systems Engineering Department, Washington State University, Pullman, WA, 235 pp
- Stone M (1978) Cross-validation: A review. *Matematische Operationsforschung Statistiken, Serie Statistics*, 9, pp. 127-139. 1978
- Supit I, van Diepen CA, de Wit AJW, Wolf J, Kabat P, Baruth B, Ludwig F (2012) Assessing climate change effects on European crop yields using the crop growth monitoring system and a weather generator. *Agric For Meteorol* 164:96–111. doi: 10.1016/j.agrformet.2012.05.005
- Tan Y, Shi L, Tong W, Hwang GTG, Wang C (2004) Multi-class tumor classification by discriminant partial least squares using microarray gene expression data and assessment of classification models. *Computational Biology and Chemistry* 28(3):235-243
- Tao FL, Yokozawa M, Xu YL, Hayashi Y, Zhang Z (2006) Climate changes and trends in phenology and yields of field crops in China, 1981-2000 *Agric.*

- Forest Meteorol. 138, 82-92
- Taylor KE (2001) Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres* 106(D7):7183-7192
- Taylor KE, Stouffer RJ, Meehl GA (2012) An overview of CMIP5 and the experiment design. *Bull Am Meteorol Soc* 93(4):485–498. doi:10.1175/bams-d-11-00094.1
- Tobias RD (1995) An introduction to partial least squares regression. In: *Proceedings of annual SAS users group international conference, 20th, Orlando, FL*
- Trenberth KE (2012) Framing the way to relate climate extremes to climate change. *Clim Chang* 115(2):283–290. doi:10.1007/s10584-012-0441-5
- Trenberth KE, Caron JM, Stepaniak DP, Worley S (2002) Evolution of El Niño-Southern Oscillation and global atmospheric surface temperatures. *Journal of Geophysical Research-Atmospheres*, 107(D7-8)
- Trnka M, Eitzinger J, Kapler P, Dubrovsky M, Semerádová D, Zalud Z, Formayer H (2007) Effect of estimated daily global solar radiation data on the results of crop growth models. *Sensors*, 7(10): 2330-2362
- Trnka M, Eitzinger J, Semerádová D, Hlavinka P, Balek J, Dubrovsky M, Kubu G, Stepanek P, Thaler S, Možny M, Zalud Z (2011) Expected changes in agroclimatic conditions in central Europe. *Clim Chang* 108(1–2):261–289. doi:10.1007/s10584-011-0025-9
- Trnka M, Roetter RP, Ruiz-Ramos M, Kersebaum KC, Olesen JE, Zalud Z, Semenov MA (2014) Adverse weather conditions for European wheat production will become more frequent with climate change. *Nat Clim Chang* 4(7):637–643. doi:10.1038/nclimate2242
- Tukey JW (1977) *Exploratory data analysis*, Addison-Wesley, Reading, 688 pp
- UCAR/NCAR (2015) *The NCAR command language (software, version 6.3.0)*. <http://dx.doi.org/10.5065/D6WD3XH5>
- Uppala SM, Kallberg PW, Simmons AJ, Andrae U, Da Costa Bechtold V, Fiorino M, Gibson JK, Haseler J, Hernandez A, Kelly GA, Li X, Onogi K, Saarinen S, Sokka N, Allan RP, Andersson E, Arpe K, Balmaseda MA, Beljaars ACM, Van De Berg L, Bidlot J, Bormann N, Caires S, Chevallier F, Dethof A, Dragosavac M, Fisher M, Fuentes M, Hagemann S, Hlm E, Hoskins BJ, Isaksen L, Janssen PAEM, Jenne R, McNally AP, Mahfouf JF, Morcrette JJ, Rayner NA, Saunders RW, Simon P, Sterl A, Trenberth KE, Untch A, Vasiljevic D, Viterbo P, Woollen J (2005) The

Referencias

- ERA-40 re-analysis. *Quarterly Journal of the Royal Meteorological Society* 131(612):2961-3012
- van den Besselaar EJM, Haylock MR, van der Schrier G, Klein Tank AMG (2011) A European Daily High-resolution Observational Gridded Data set of Sea Level Pressure. *J. Geophys. Res.*, 116, D11110, doi: 10.1029/2010JD015468
- Van der Pol B (1946) The fundamental principles of frequency modulation. *Proc IEE* 93:153–158
- Van Herwaarden AF, Farquhar GD, Angus JF, Richards RA, Howe GN (1998) ‘Haying-off’, the negative grain yield response of dryland wheat to nitrogen fertilizer. Biomass, grain yield, and water use. *Aust. J. Agr. Res.*, 49, 1067-1082
- Van Ittersum MK, Donatelli M (2003) Modelling cropping systems - highlights of the symposium and preface to the special issues. *Eur. J. Agron.*, 18, 187-197
- Van Ittersum MK, Leffelaar PA, van Keulen H, Kropff MJ, Bastiaans L, Goudriaan J (2003) On approaches and applications of the Wageningen crop models. *Eur. J. Agron.*, 18, 201-234
- Van Loon H, Rogers J (1978) The seesaw in winter temperature between Greenland and northern Europe. Part I: general description. *Monthly Weather Review* 106(3):296-310
- Vicente-Serrano SM, Begueria S, Lopez-Moreno JI (2010) A multiscalar drought index sensitive to global warming: the standardized precipitation evapotranspiration index. *J Clim* 23(7):1696–1718. doi: 10.1175/2009jcli2909.1
- Vicente-Serrano SM, Beguería S, Lorenzo-Lacruz J, Camarero J, López-Moreno J, Azorin-Molina C, Revuelto J, Morán-Tejeda E, Sanchez-Lorenzo A (2012) Performance of Drought Indices for Ecological, Agricultural, and Hydrological Applications. *Earth Interact.*, 16, 1–27, doi: 10.1175/2012EI000434.1
- Vicente-Serrano SM, Cuadrat-Prats JM, Romo A (2006) Early prediction of crop production using drought indices at different time-scales and remote sensing data: application in the Ebro valley (north-east Spain). *Int J Remote Sens* 27(3):511–518
- Vicente-Serrano SM, Lopez-Moreno JI, Begueria S, Lorenzo-Lacruz J, Sanchez Lorenzo A, Garcia-Ruiz JM, Azorin-Molina C, Moran-Tejeda E, Revuelto J, Trigo R, Coelho F, Espejo F (2014) Evidence of increasing drought severity caused by temperature rise in Southern Europe. *Environ Res Lett*

- 9(4):9. doi:10.1088/1748-9326/9/4/044001
- Villegas D, Alfaro C, Ammar K, Cátedra MM, Crossa J, García del Moral LF, Royo C (2016) Daylength, Temperature and Solar Radiation Effects on the Phenology and Yield Formation of Spring Durum Wheat. *J Agro Crop Sci*, 202: 203-216. doi:10.1111/jac.12146
- Vitart F, Ardilouze C, Bonet A, Brookshaw A, Chen M, Codorean C, Déqué M, Ferranti L, Fucile E, Fuentes M, Hendon H, Hodgson J, Kang H-S, Kumar A, Lin H, Liu G, Liu X, Malguzzi P, Mallas I, Manoussakis M, Mastrangelo D, MacLachlan C, McLean P, Minami A, Mladek R, Nakazawa T, Najm S, Nie Y, Rixen M, Robertson AW, Ruti P, Sun C, Takaya Y, Tolstykh M, Venuti F, Waliser D, Woolnough S, Wu T, Won DJ, Xiao H, Zaripov R, Zhang L (2017) The Subseasonal to Seasonal (S2S) prediction project database. *Bulletin of the American Meteorological Society*, 98(1): 163-173. doi:10.1175/BAMS-D-16-0017.1
- Voldoire A, Sanchez-Gomez E, Salas y Méliá D, Decharme B, Cassou C, Sénési S, Valcke S, Beau I, Alias A, Chevallier M, Déqué M, Deshayes J, Douville H, Fernandez E, Madec G, Maisonnave E, Moine MP, Planton S, Saint-Martin D, Szopa S, Tyteca S, Alkama R, Belamari S, Braun A, Coquart L, Chauvin F (2013) The CNRM-CM5.1 global climate model: description and basic evaluation. *Climate Dynamics* 40(9-10):2091-2121
- von Salzen K, Scinocca JF, McFarlane NA, Li J, Cole JNS, Plummer D, Versegny D, Reader MC, Ma X, Lazare M, Solheim L (2013) The Canadian fourth generation atmospheric global climate model (CanAM4). Part I: representation of physical processes. *Atmosphere-Ocean* 51(1):104-125
- Vong NQ, Murata Y (1979) Studies on the physiological characteristics of C3 and C4 crop species I. The effects of air temperature on the apparent photosynthesis, dark respiration, and nutrient absorption of some crops. *Japanese Journal of Crop Science*, 46(1):45-52
- Walker GT, Bliss EW (1928) World weather IV Some applications to seasonal foreshadowing. *Memoirs of the Royal Meteorological Society* 3(24):81-95
- Wallace JM, Fu Q, Smoliak BV, Lin P, Johanson CM (2012) Simulated versus observed patterns of warming over the extratropical Northern Hemisphere continents during the cold season. *Proc. Natl. Acad. Sci. (USA)*, 109, 14 337-14 342
- Wallace JM, Gutzler DS (1981) Teleconnections in the geopotential height field during the Northern Hemisphere winter. *Monthly Weather Review* 109(4):784-812

Referencias

- Watanabe M, Suzuki T, O'ishi R, Komuro Y, Watanabe S, Emori S, Takemura T, Chikira M, Ogura T, Sekiguchi M, Takata K, Yamazaki D, Yokohata T, Nozawa T, Hasumi H, Tatebe H, Kimoto M (2010) Improved climate simulation by MIROC5. Mean states, variability, and climate sensitivity. *Journal of Climate* 23(23):6312-6335
- Watson J, Challinor AJ, Fricker TE, Ferro CAT (2015) Comparing the effects of calibration and climate errors on a statistical crop model and a process-based crop model. *Climatic Change* 132(1): 93-109. doi: 10.1007/s10584-014-1264-3
- White JW, Hoogenboom G, Kimball BA, Wall GW (2011) Methodologies for simulating impacts of climate change on crop production. *Field Crop Res* 124(3):357–368. doi: 10.1016/j.fcr.2011.07.001
- Wilby RL, Wigley TML, Conway D, Jones PD, Hewitson BC, Main J, Wilks DS (1998) Statistical downscaling of general circulation model output: a comparison of methods. *Water Resources Research* 34(11): 2995–3008, doi: 10.1029/98WR02577
- Wilcox J, Makowski D (2014) A meta-analysis of the predicted effects of climate change on wheat yields using simulation studies. *Field Crop Res.* 156,180–190
- Wild M (2016) Decadal changes in radiative fluxes at land and ocean surfaces and their relevance for global warming. *Wiley Interdisciplinary Reviews-Climate Change* 7(1): 91-107. doi: 10.1002/wcc.372
- Wilks D (2016) The stippling shows statistically significant gridpoints: How Research Results are Routinely Overstated and Over-interpreted, and What to Do About It. *Bull. Amer. Meteor. Soc.* doi:10.1175/BAMS-D-15-00267.1, in press
- Wilks D (2006) *Statistical methods in the atmospheric sciences*, 2nd edn. Academic
- WMO (2012) *Standardized precipitation index. User Guide*. Weather Climate Water, CH 1211 Geneva 2, Switzerland
- WMO (2013) *The global climate 2001-2010. A decade of climatic extremes. summary report*. Report
- Wold H (1966) Estimation of principal components and related models by iterative least squares. *Multivariate Analysis*, P. R. Krishnaiah, Ed., Academic Press, 391–420
- Wold S (2001) Personal memories of the early PLS development. *Chemometrics and Intelligent Laboratory Systems*, 58, 83–84

- Wold S, Ruhe A, Wold H, Dunn WJ (1984) The collinearity problema in linear-regression. The partial least squares (PLS) approach to generalized inverses. *Siam J Sci Stat Comput* 5(3):735–743
- Woodcock F, Engel C (2005) Operational consensus forecasts. *Wea. Forecasting*, 20, 101–111, doi: <http://dx.doi.org/10.1175/WAF-831.1>
- Worsley KJ (1997) An overview and some new developments in the statistical analysis of PET and fMRI data. *Human Brain Mapping*, 5, 254–258
- Wu Z, Huang NE (2009) Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Adv Adapt Data Anal* 1:1–41
- Wu Z, Huang NE (2004) A study of the characteristics of white noise using the empirical mode decomposition method. *Proc R S Lond* 460A:1597–1611
- Wu Z, Huang NE (2005) Statistical significant test of intrinsic mode functions. In: Huang NE, Shen SSP (eds) *Hilbert–Huang transform: introduction and applications*. World Scientific, Singapore, pp 125–148
- Wu Z, Huang NE, Long S, Peng C (2007) On the trend, detrending, and variability of nonlinear and nonstationary time series. *Proc. Natl. Acad. Sci. (USA)*, 104, 14 889–14 894, doi:<http://dx.doi.org/10.1073/pnas.0701020104>
- Wu Z, Huang NE, Wallace JM, Smoliak BV, Chen X (2011) On the Time-Varying Trend in Global-mean Surface Temperature. *Clim. Dyn.*, 37, 759–773, doi: <http://dx.doi.org/10.1007/s00382-011-1128-8>
- Wu J, Liu M, Lu A, He B (2014) The variation of the water deficit during the winter wheat growing season and its impact on crop yield in the north China plain. *Int J Biometeorol* 58(9):1951–1960. doi: 10.1007/s00484-014-0798-4
- Yang RC, Stanton D, Blade SF, Helm J, Spaner D, Wright S, Domitruk D (2006) Isoyield analysis of barley cultivar trials in the Canadian prairies. *J. Agron. Crop Sci.* 192(4): 284–294, doi: 10.1111/j.1439-037X.2006.00209.x
- Yue S, Wang C (2004) The Mann-Kendall test modified by effective sample size to detect trend in serially correlated hydrological series. *Water Resources Management* 18(3):201-218
- Zadoks JC, Chang TT, Konzak CF (1974) A decimal code for the growth stages of cereals. *Weeds Res.*, 14: 415-421
- Zhang H, Oweis T (1999) Water–yield relations and optimal irrigation scheduling of wheat in the Mediterranean region. *Agric. Water Manage.*, 38, 195-211
- Zhang XY, You MZ, Wan XY (1999) Effects of water deficit on winter wheat yield during its different development stage. *Acta Agric. Boreali Sinica*,

Referencias

14, 1-5 (In Chinese)

Referencias

Apéndice A: Modelos CMIP5



A continuación, se muestra una tabla con los modelos CMIP5 utilizados en esta investigación. La primera columna indica el acrónimo del modelo. La segunda columna muestra el nombre oficial del modelo, la tercera el nombre del centro modelizador, la cuarta el país donde se encuentra el centro, la quinta la resolución atmosférica (celda horizontal y número de niveles verticales). Finalmente, la sexta columna muestra la referencia principal del modelo.

Acrónimo del modelo	Nombre del modelo	Centro Modelizador (ID Institución)	País	Resolución Atmosférica	Referencia
CCSM4*	Community Climate System Model, version 4	National Center of Atmospheric Research (NCAR)	Estados Unidos	0.9°x1.25°, L27	Gent et al. (2011) Bitz (2012)
CESM1-CAM5	Community Earth System Model version 1 with the Community Atmospheric Model, version 5	National Science Foundation, U.S. Department of Energy, National Center for Atmospheric Research (NSF-DOE-NCAR)	Estados Unidos	0.9°x1.25°, L27	Hurrell et al. (2013)
CMCC-CESM*	Centro Euro-Mediterraneo per I Cambiamenti Climatici Carbon Cycle Earth System Model	Centro Euro-Mediterraneo per I Cambiamenti Climatici (CMCC)	Italia	1.875°x1.875° (T63), L95°	Fogli et al. (2009)

Acrónimo del modelo	Nombre del modelo	Centro Modelizador (ID Institución)	País	Resolución Atmosférica	Referencia
CNRM-CM5*	Centre National de Recherches Météorologiques Coupled Global Climate Model, version 5	Centre National de Recherches Météorologiques (CNRM-CERFACS)	Francia	TL127, L31	Voldoire et al. (2013)
CanESM2	Second Generation Canadian Earth System Model	Canadian Centre for Climate Modelling and Analysis (CCCMA)	Cánada	Espectral T63, L35	von Salzen et al. (2013)
GFDL-ESM2M*	Geophysical Fluid Dynamics Laboratory Earth System Model with Modular Ocean Model, version 4 (MOM4) component	NOAA Geophysical Fluid Dynamics Laboratory (NOAA-GFDL)	Estados Unidos	2.0°x2.5° M45, L24	Dunne et al. (2013)
GISS-E2-H	Goddard Institute for Space Studies Model E2, coupled with Hybrid Coordinate Ocean Model (HYCOM)	NASA Goddard Institute for Space Studies (NASA GISS)	Estados Unidos	2.0°x2.5°, L40	Schmidt et al. (2014)
HadGEM2-CC*	Hadley Centre Global Environment Model, version 2, Carbon Cycle	Met Office Hadley Centre (MOHC)	Reino Unido	1.25°x1.875°, N96, L60	Collins et al. (2011) Martin et al. (2011)

Apéndice

Acrónimo del modelo	Nombre del modelo	Centro Modelizador (ID Institución)	País	Resolución Atmosférica	Referencia
HADGEM2-ES*	Hadley Centre Global Environment Model, version 2, Earth System	Met Office Hadley Centre (MOHC/INPE)	Reino Unido	1.25°x1.875° N96, L38	Collins et al. (2011) Martin et al. (2011)
MIROC5*	Model for Interdisciplinary Research on Climate, version 5	National Institute for Environmental Studies and Japan Agency for Marine-Earth Science and Technology (MIROC)	Japón	1.40625°x 1.40625°, T85, L40	Watanabe et al. (2010)
MPI-ESM-MR*	Max Planck Institute Earth System Model, medium resolution Norwegian Earth System Model, version 1, intermediate resolution	Max Planck Institute for Meteorology (MPI-M)	Alemania	1.8°x1.8°, T63, L95	Stevens et al. (2013) Jungclauss et al. (2013)
NorESM1-M*		Norwegian Climate Centre (NCC)	Noruega	1.9°x 2.5°, L26	Iversen et al. (2013)

