



**VNiVERSiDAD
D SALAMANCA**

FACULTAD DE CIENCIAS

TRABAJO FIN DE GRADO EN ESTADÍSTICA

Optimización de Redes de Transporte en España mediante Algoritmos Biológicos

Autor: Tomás Jiménez Sánchez

Tutor: José Ángel Domínguez Pérez

Curso Académico 2023-2024


**UNIVERSIDAD DE SALAMANCA
FACULTAD DE CIENCIAS**

TRABAJO FIN DE GRADO EN ESTADÍSTICA

Optimización de Redes de Transporte en España mediante Algoritmos Biológicos

Salamanca, a 2 de Julio de 2024

El autor:

A handwritten signature in black ink, consisting of a large, stylized 'T' followed by a series of loops and a horizontal line extending to the right.

Firmado: Tomás Jiménez Sánchez

UNIVERSIDAD DE SALAMANCA
FACULTAD DE CIENCIAS

**DOCUMENTO ACREDITATIVO DE PRESENTACIÓN DEL
TRABAJO FIN DE GRADO EN ESTADÍSTICA
CERTIFICADO DEL TUTOR**

D. José Ángel Domínguez Pérez, profesor del Departamento de Matemáticas de la Universidad de Salamanca,

HACE CONSTAR:

Que el trabajo titulado “Optimización de Redes de Transporte en España mediante Algoritmos Biológicos”, que se presenta, ha sido realizado por Tomás Jiménez Sánchez, con DNI 70843937G y constituye la memoria del trabajo realizado para la superación de la asignatura Trabajo Fin de Grado en Estadística de esta universidad.

Salamanca, a 2 de Julio de 2024

El Tutor:



Firmado: José Ángel Domínguez Pérez

Resumen

El trabajo fin de grado explora la aplicación de algoritmos biológicos para la optimización de redes de transporte en España, específicamente utilizando un modelo matemático basado en el comportamiento del moho mucilaginoso *Physarum polycephalum*. Este organismo ha mostrado capacidad para desarrollar redes eficientes de transporte de nutrientes, lo que inspira la metodología para planificar redes de transporte humano más eficientes y menos costosas.

Los objetivos principales del trabajo incluyen el desarrollo de un modelo que pueda replicar la eficiencia del moho en la formación de redes robustas y eficientes, la implementación de este modelo utilizando datos reales de redes de transporte en España, y la validación de su efectividad a través de la comparación con las redes existentes. Se espera que el modelo contribuya a una planificación más eficiente, sostenible y económica de las redes de transporte, minimizando también las emisiones contaminantes y mejorando la conectividad regional. También se incluye un análisis comparativo de la red actual frente a los resultados obtenidos con el nuevo modelo, buscando demostrar la aplicabilidad y beneficios del enfoque propuesto.

Palabras clave

- Optimización de redes de transporte
- Algoritmos biológicos
- Modelo matemático
- *Physarum polycephalum*
- Análisis logístico
- Simulación de redes
- Transporte eficiente

Abstract

The thesis explores the application of biological algorithms for the optimization of transportation networks in Spain, specifically using a mathematical model based on the behavior of the slime mold *Physarum polycephalum*. This organism has demonstrated the ability to develop efficient nutrient transport networks, which inspires the methodology for planning more efficient and less costly human transportation networks.

The main objectives of the study include the development of a model that can replicate the efficiency of the mold in forming robust and efficient networks, the implementation of this

model using real data from transportation networks in Spain, and the validation of its effectiveness through comparison with existing networks. The model is expected to contribute to more efficient, sustainable, and economical transportation network planning, also minimizing pollutant emissions and improving regional connectivity. The study also includes a comparative analysis of the current network against the results obtained with the new model, seeking to demonstrate the applicability and benefits of the proposed approach.

Key words

- Transportation network optimization
- Biological algorithms
- Mathematical model
- Physarum polycephalum
- Logistic analysis
- Network simulation
- Efficient transportation

Índice de Contenidos

Resumen	iii
Palabras clave	iii
Abstract	iii
Key words	iv
Índice de Contenidos	v
INTRODUCCIÓN	1
<i>Redes de transporte y su impacto en la sociedad</i>	1
<i>El transporte ferroviario como solución</i>	1
<i>Objetivos del trabajo</i>	2
<i>Objetivos Específicos</i>	2
<i>Metodología</i>	4
<i>Impacto Esperado</i>	5
<i>Estructura del trabajo</i>	6
<i>Bases de datos y preprocesamiento</i>	9
PLANTEAMIENTO DEL PROBLEMA	13
<i>Problemas de diseño de una red de transporte</i>	13
<i>Solución por algoritmos biológicos</i>	14
<i>Aplicaciones del algoritmo del Physarum Polycephalum</i>	15
MODELO MATEMÁTICO PARA EL HONGO PHYSARUM	18
<i>Elementos del modelo</i>	18
<i>Ley de Conservación del Flujo</i>	19
<i>Función de Coste</i>	20
<i>Eliminación de caminos en decadencia</i>	21
<i>Criterio de parada</i>	21
IMPLEMENTACIÓN DEL MODELO MATEMÁTICO	22
<i>Justificación y Fundamento Teórico</i>	22
<i>Descripción del Algoritmo de Múltiples Fuentes</i>	22
<i>Limitaciones y Desafíos</i>	24
<i>Análisis de Complejidad temporal y espacial del algoritmo</i>	24
<i>Posibles Mejoras</i>	26
RESULTADOS	27
<i>Comparativa con diferentes parámetros</i>	27
<i>Comparativa con la red actual</i>	34
<i>Propuesta de mejora</i>	40

CONCLUSIONES	44
BIBLIOGRAFÍA Y REFERENCIAS	46
ANEXO	48

INTRODUCCIÓN

Redes de transporte y su impacto en la sociedad

El problema de las redes de transporte terrestre de personas y mercancías entre los diferentes lugares de un país y la contaminación que generan los medios de transporte es una cuestión crítica que afecta de manera significativa a todas las sociedades, y en particular a la sociedad española. El rápido crecimiento urbano ha llevado a un aumento sustancial en el número de vehículos en la red de carreteras, generando no sólo congestión del tráfico [16,17] sino también emisiones contaminantes en ciudades y áreas metropolitanas, que afrontan problemas derivados de esta contaminación para el medioambiente y la salud, además de su impacto en el aumento del coste de vida.

Los medios de transporte creados en el siglo XX, basados en motores que consumen combustibles fósiles y se desplazan por una red de carreteras, tan ampliamente utilizados en España como en el resto del mundo, contribuyen de manera considerable a las emisiones de gases contaminantes de efecto invernadero, acelerando el cambio climático. La contaminación del aire derivada de esos vehículos motorizados tiene también un impacto directo en la salud de la población: las partículas y los compuestos emitidos durante la combustión pueden agravar problemas respiratorios existentes y aumentar la incidencia de enfermedades cardiovasculares. Este impacto en la salud no solo afecta el bienestar de los ciudadanos, sino que también representa una carga económica para el sistema de salud pública y la productividad laboral [1, 2].

Además, la dependencia continua de los combustibles fósiles en el transporte plantea desafíos específicos para España en términos de seguridad energética y vulnerabilidad a las fluctuaciones en los precios del petróleo. La economía del país está intrínsecamente ligada a la importación de combustibles, lo que puede afectar su estabilidad económica. La transición hacia opciones de movilidad más sostenibles, como vehículos eléctricos y sistemas de transporte público eficientes, se convierte en una necesidad imperante para abordar estos problemas y asegurar un futuro más saludable y sostenible para la sociedad española [3].

El transporte ferroviario como solución

De todos los medios de transporte terrestres el ferrocarril y sus trenes eléctricos emergen como una solución prometedora para abordar los desafíos del transporte y la contaminación. España cuenta con una extensa red ferroviaria, siendo la segunda del mundo con mas kilómetros de alta velocidad, únicamente por detrás de China [4], una red que si se fortalece y moderniza, puede desempeñar un papel crucial en la reducción de la congestión del tráfico por carretera y las emisiones contaminantes. Además de esta infraestructura ferroviaria muy avanzada, el ferrocarril ofrece otras ventajas respecto a otros medios y redes de transporte

En primer lugar, el tren eléctrico constituye una alternativa eficiente y sostenible al transporte por carretera, especialmente en distancias medias y largas. La electrificación de las líneas ferroviarias y el impulso de trenes de alta velocidad no solo mejoran la rapidez de los

desplazamientos y la accesibilidad para todas las personas, sino que también reducen significativamente las emisiones de gases de efecto invernadero en comparación con los vehículos de combustibles fósiles [5].

En segundo lugar, la inversión en infraestructuras ferroviarias modernas puede fomentar el uso del transporte público, disminuyendo así la dependencia del automóvil individual que se desplaza por carretera. Una red ferroviaria eficiente, diseñada con perspectiva de cohesión social, conecta no solo las principales ciudades, sino también áreas rurales, evitando su despoblación, facilitando que las personas no tengan que residir en las ciudades para poder acudir a su trabajo.

Además, el tren eléctrico no solo es una solución ambientalmente amigable, sino que también aborda preocupaciones relacionadas con la seguridad energética. Al diversificar las fuentes de energía utilizadas en el transporte hacia la electricidad, España puede reducir su dependencia de los combustibles fósiles, mejorando la resiliencia frente a las fluctuaciones de precios en el mercado internacional del petróleo, el combustible fósil más utilizado en el transporte por carretera [6].

Objetivos del trabajo

El objetivo principal de este trabajo es investigar y aplicar algoritmos biológicos, especialmente aquellos inspirados en el moho mucilaginoso *Physarum polycephalum*, para optimizar las redes de transporte en España. La meta es desarrollar y validar un modelo matemático que permita la planificación eficiente de redes de transporte, abordando tanto los aspectos logísticos y de conectividad como la sostenibilidad ambiental. Este modelo pretende mejorar la eficiencia en la distribución de flujos de transporte, reducir los costos de construcción y mantenimiento de infraestructuras, y minimizar las emisiones de gases contaminantes.

Objetivos Específicos

- Desarrollo de un Modelo de Optimización

Meta: Desarrollar un modelo matemático inspirado en el comportamiento del *Physarum polycephalum* que pueda aplicarse a la planificación y optimización de redes de transporte. Este modelo debe ser capaz de replicar el comportamiento natural del moho en la creación de redes eficientes y robustas para la distribución de flujos de transporte.

Descripción: El modelo se basará en las propiedades del *Physarum polycephalum*, conocido por su capacidad para encontrar rutas eficientes y formar redes de conexión óptimas entre nodos de recursos (fuentes de alimento en su entorno natural). El desarrollo incluirá la formulación de ecuaciones matemáticas que describan el comportamiento de flujo de transporte en una red, la adaptación de estos principios para aplicarlos a redes de transporte humano, y la implementación del modelo en un entorno de programación para su simulación y prueba.

- Implementación y Validación del Modelo

Meta: Implementar el modelo desarrollado utilizando datos reales de redes de transporte en España y validar su efectividad comparando los resultados con las redes de transporte existentes.

Descripción: Esta fase del trabajo implicará la recopilación de datos geográficos, como las ubicaciones de nodos (ciudades) y la demanda de transporte entre ellos. Se utilizarán herramientas de programación como Python y RStudio para implementar el modelo y realizar simulaciones. La validación se llevará a cabo mediante la comparación de los resultados obtenidos con las características de las redes de transporte actuales, evaluando métricas como la eficiencia del flujo, la reducción de costos y la conectividad mejorada.

- Estudio de Caso en Redes Ferroviarias

Meta: Aplicar el modelo desarrollado a la red ferroviaria española como un estudio de caso específico para demostrar su aplicabilidad y beneficios en un contexto real.

Descripción: La red ferroviaria española, con su infraestructura de alta velocidad y su extensa conectividad, ofrece un caso de estudio ideal para probar el modelo. Se realizarán simulaciones para evaluar cómo el modelo puede optimizar la planificación de la red, mejorando la eficiencia de la distribución de flujos de transporte, reduciendo los costos asociados, y potencialmente aumentando la accesibilidad y conectividad entre diferentes regiones. Este objetivo permitirá demostrar la capacidad del modelo para manejar un sistema de transporte complejo y mejorar su rendimiento.

- Propuesta de Mejora y Expansión del Modelo

Meta: Desarrollar recomendaciones para la mejora continua del modelo y explorar su adaptación para diferentes tipos de redes de transporte y contextos geográficos.

Descripción: Con base en los resultados obtenidos del estudio de caso y las simulaciones, se identificarán áreas para la mejora del modelo. Esto incluirá ajustes en las ecuaciones y parámetros del modelo, así como la consideración de factores adicionales como las variaciones estacionales en la demanda de transporte y la integración con otros modos de transporte. Además, se explorará cómo el modelo puede adaptarse a otros contextos geográficos o tipos de redes, como las redes de transporte urbano o las redes de carreteras interurbanas. Estas recomendaciones servirán para potenciar la utilidad del modelo en una gama más amplia de aplicaciones y mejorar su precisión y eficiencia en la optimización de redes de transporte.

Metodología

- Revisión de la Literatura

Se realizará una revisión exhaustiva de la literatura existente sobre algoritmos biológicos y su aplicación en la optimización de redes. Se tendrán en cuenta estudios de casos anteriores, análisis comparativos de algoritmos y desarrollos teóricos que informen sobre las mejores prácticas y enfoques para la optimización de redes de transporte.

- Desarrollo del Modelo

El desarrollo del modelo incluirá la formulación de ecuaciones matemáticas basadas en el comportamiento del *Physarum polycephalum*, la definición de parámetros críticos, y la adaptación de estos principios a la planificación de redes de transporte. Utilizando técnicas de simulación y herramientas de programación, se implementará el modelo y se realizarán pruebas para validar su efectividad en diferentes escenarios.

- Implementación de Simulaciones

Se utilizarán datos reales de redes de transporte en España para implementar y probar el modelo. Se realizarán simulaciones para evaluar el rendimiento del modelo en términos de eficiencia de flujo, reducción de costos, y mejora de la conectividad. Los resultados de estas simulaciones se analizarán y compararán con las redes de transporte existentes para validar la efectividad del modelo.

- Análisis de Resultados y Validación

Los resultados de las simulaciones se analizarán para evaluar la efectividad del modelo. Se utilizarán métricas específicas, como la eficiencia del flujo de transporte, la reducción de costos de construcción y mantenimiento, y la mejora de la conectividad entre nodos. La validación del modelo se llevará a cabo mediante la comparación de estos resultados con las características de las redes de transporte actuales y la identificación de áreas de mejora.

- Desarrollo de Recomendaciones

Con base en el análisis de los resultados, se desarrollarán recomendaciones para la mejora continua del modelo. Esto incluirá ajustes en los parámetros y ecuaciones del modelo, así como sugerencias para su adaptación a diferentes contextos y tipos de redes de transporte. Estas recomendaciones se documentarán para guiar futuras investigaciones y aplicaciones del modelo.

Impacto Esperado

- Eficiencia en la Planificación de Redes

Se espera que el modelo desarrollado proporcione una metodología innovadora para la planificación y optimización de redes de transporte en España. Al aplicar algoritmos biológicos, el modelo puede ofrecer soluciones más eficientes para la distribución de flujos de transporte, reduciendo los costos y mejorando la conectividad entre regiones.

- Sostenibilidad Ambiental

El modelo también tiene el potencial de contribuir a la sostenibilidad ambiental al minimizar las emisiones de gases contaminantes. Al optimizar la distribución de flujos de transporte y reducir la dependencia de combustibles fósiles, el modelo puede ayudar a crear sistemas de transporte más sostenibles y ecológicos.

- Mejora de la Movilidad

Al mejorar la eficiencia de las redes de transporte y aumentar la conectividad entre diferentes regiones, el modelo puede contribuir a mejorar la movilidad y accesibilidad para los ciudadanos. Esto puede facilitar el acceso a oportunidades económicas, sociales y culturales, mejorando la calidad de vida en general.

- Innovación en la Planificación de Infraestructuras

El uso de algoritmos biológicos para la optimización de redes de transporte representa una innovación significativa en la planificación de infraestructuras. Este enfoque puede inspirar nuevas investigaciones y aplicaciones en otros campos, como la logística y las telecomunicaciones, ampliando el impacto de la metodología desarrollada en este trabajo.

- Expansión del Conocimiento

Finalmente, el trabajo contribuirá al conocimiento académico y técnico en el campo de la optimización de redes de transporte, proporcionando un modelo y una metodología que pueden ser utilizados como base para futuras investigaciones y desarrollos en este campo.

Los objetivos del trabajo están diseñados para explorar y aplicar algoritmos biológicos en la optimización de redes de transporte en España. Desde la evaluación de algoritmos biológicos hasta el desarrollo, implementación y validación de un modelo inspirado en el *Physarum polycephalum*, estos objetivos buscan mejorar la eficiencia, sostenibilidad y conectividad de las redes de transporte. Las metodologías y recomendaciones desarrolladas a partir de este trabajo tienen el potencial de ofrecer beneficios significativos en la planificación de infraestructuras y la movilidad urbana, contribuyendo a la creación de sistemas de transporte más eficientes y sostenibles.

Estructura del trabajo

El presente trabajo se organiza en varias secciones que abordan de manera integral los distintos aspectos de la optimización de redes de transporte mediante algoritmos biológicos. Esta estructura está diseñada para guiar al lector desde una comprensión básica del problema y la justificación del enfoque, hasta la implementación técnica y los resultados del estudio. A continuación, se presenta una visión general detallada de la estructura del trabajo.

- Planteamiento del Problema

- Redes de transporte y su impacto en la sociedad

En esta sección, se describe el contexto y la importancia de las redes de transporte, destacando su impacto en la sociedad moderna. Se discuten los desafíos actuales relacionados con la congestión del tráfico, la contaminación ambiental y la ineficiencia en la distribución de flujos de transporte. Se hace hincapié en la situación específica de España, donde estos problemas son especialmente relevantes debido al crecimiento urbano y la alta densidad poblacional en áreas metropolitanas.

- El transporte ferroviario como solución

Aquí se analiza cómo el transporte ferroviario puede ser una solución viable para los problemas identificados. Se destacan las ventajas del transporte ferroviario, como la reducción de emisiones y la eficiencia en el manejo de grandes volúmenes de pasajeros y mercancías. Se menciona la extensa red ferroviaria de alta velocidad en España y su potencial para desempeñar un papel crucial en la optimización de la movilidad y la sostenibilidad.

- Problemas de diseño de una red de transporte

Esta subsección introduce el problema de diseño de una red de transporte (Network Design Problem, NDP), describiendo su relevancia en la planificación y gestión de infraestructuras. Se explican los conceptos básicos del NDP, incluyendo la selección de subgrafos dentro de una red ponderada y la necesidad de equilibrar costos, rendimiento y tolerancia a fallos.

- Solución por algoritmos biológicos

Se presentan los algoritmos biológicos como una solución innovadora para el NDP. Se detallan ejemplos de algoritmos inspirados en la biología, como el Algoritmo de Optimización de Colonia de Hormigas (ACO) y el modelo basado en el moho mucilaginoso *Physarum polycephalum*. Se discuten las propiedades y el comportamiento de estos organismos que los hacen adecuados para la optimización de redes de transporte.

- Aplicaciones del algoritmo del *Physarum polycephalum*

Se examinan estudios de caso y aplicaciones prácticas del algoritmo inspirado en el *Physarum polycephalum*, incluyendo su uso para replicar redes de transporte existentes como el metro de Tokio. Se destaca cómo

estos estudios demuestran la capacidad del algoritmo para crear redes eficientes y adaptativas.

- **Marco teórico**

- Algoritmos biológicos y su relevancia

Esta sección proporciona una revisión exhaustiva de la literatura sobre algoritmos biológicos. Se detallan los fundamentos teóricos de algoritmos como ACO y el modelo del *Physarum polycephalum*, explicando cómo estos enfoques se inspiran en procesos naturales para resolver problemas complejos de optimización.

- Modelado matemático

Aquí se desarrollan las ecuaciones matemáticas y los principios que sustentan el modelo de optimización basado en el *Physarum polycephalum*. Se explican conceptos clave como el flujo de Poiseuille, la ley de conservación del flujo y la función de coste, que son esenciales para la implementación del modelo.

- **Desarrollo del Modelo**

- Formulación del modelo

Se presenta en detalle la formulación del modelo matemático inspirado en el *Physarum polycephalum*. Se describen las ecuaciones y los parámetros utilizados, así como los supuestos y simplificaciones necesarios para adaptar el comportamiento del moho a la planificación de redes de transporte humanas.

- Implementación del modelo

Esta subsección detalla el proceso de implementación del modelo utilizando herramientas de programación como Python y RStudio. Se describen los pasos para preparar los datos de entrada, configurar los parámetros del modelo y ejecutar las simulaciones.

- Validación del modelo

Se discuten los métodos utilizados para validar el modelo, incluyendo la comparación de los resultados obtenidos con las características de las redes de transporte existentes. Se describen las métricas de rendimiento y los criterios de evaluación utilizados para medir la eficacia del modelo.

- **Resultados y Análisis**

- Simulaciones y resultados

Se presentan los resultados de las simulaciones realizadas con el modelo de optimización basado en el *Physarum polycephalum*. Se muestran visualizaciones y análisis de los patrones emergentes, la eficiencia del flujo de transporte y las mejoras en la conectividad.

- Comparación con redes existentes

Se comparan los resultados del modelo con las redes de transporte actuales en España, evaluando las mejoras en términos de eficiencia, reducción de costos y sostenibilidad. Se discuten las implicaciones de estos resultados para la planificación de infraestructuras de transporte.

- Análisis de sensibilidad

Se realiza un análisis de sensibilidad para evaluar cómo cambios en los parámetros del modelo afectan los resultados. Este análisis ayuda a identificar los factores críticos que influyen en la eficacia del modelo y proporciona información para su ajuste y mejora continua.

- **Estudio de Caso: Red Ferroviaria Española**

- Descripción del caso de estudio

Se describe la red ferroviaria española, destacando su infraestructura, la distribución de flujos de transporte y los desafíos actuales. Se justifica la elección de esta red como caso de estudio para aplicar el modelo desarrollado.

- Aplicación del modelo

Se detallan los pasos para aplicar el modelo de optimización a la red ferroviaria española, incluyendo la recopilación de datos, la configuración del modelo y la ejecución de simulaciones específicas.

- Resultados y discusión

Se presentan y analizan los resultados de la aplicación del modelo a la red ferroviaria española. Se discuten las mejoras en la eficiencia del flujo de transporte, la reducción de costos y las implicaciones para la planificación futura de la red.

- **Conclusiones**

- Resumen de hallazgos

Se resumen los hallazgos principales del trabajo, destacando cómo el modelo de optimización basado en el *Physarum polycephalum* puede mejorar la planificación de redes de transporte en España. Se discuten las contribuciones del trabajo al conocimiento académico y técnico en el campo de la optimización de redes.

- Implicaciones prácticas

Se discuten las implicaciones prácticas de los resultados del trabajo para la planificación y gestión de infraestructuras de transporte en España. Se destaca cómo las metodologías desarrolladas pueden ser utilizadas por

planificadores y responsables de políticas para crear sistemas de transporte más eficientes y sostenibles.

- **Bibliografía**

Se proporciona una lista completa de las referencias utilizadas a lo largo del trabajo, organizada de manera que facilite la consulta y verificación de la información presentada. Esta sección incluye artículos científicos, libros, y fuentes de datos que sustentan los fundamentos teóricos y prácticos del trabajo.

- **Apéndices**

Se proporcionan todos los códigos utilizados para desarrollar y ejecutar los resultados mostrados en el estudio

Bases de datos y preprocesamiento

El uso de bases de datos es fundamental en la optimización de redes de transporte, ya que proporcionan la información necesaria para modelar y analizar las infraestructuras existentes y proyectar mejoras. En este trabajo, se emplearon dos conjuntos de datos ofrecidos por el Instituto Geográfico Nacional de España. Estos conjuntos contienen variables críticas para el análisis de las redes de transporte, incluyendo información geográfica y demográfica que permite una comprensión detallada de la distribución y las características de los nodos (ciudades) y sus conexiones.

- **Descripción de las Bases de Datos**

- Conjunto de datos de capitales de provincia

Este conjunto de datos incluye información detallada sobre las capitales de provincia en España. Las principales variables contenidas en esta base de datos son:

- Nombre de la ciudad: Identificación de cada capital de provincia.
- Coordenadas geográficas: Latitud y longitud que permiten ubicar geográficamente cada ciudad.
- Población: Número de habitantes en cada capital de provincia, una variable crucial para entender la demanda de transporte y la conectividad requerida.

- **Proceso de preprocesamiento**

- Herramientas y entorno de desarrollo

El preprocesamiento de las bases de datos se llevó a cabo utilizando RStudio, un entorno de desarrollo integrado que utiliza el lenguaje de programación R. Este entorno es conocido por su capacidad para manejar grandes volúmenes de datos y realizar análisis estadísticos avanzados. Para

la implementación y el desarrollo de algoritmos, se utilizó Python debido a su versatilidad y la disponibilidad de bibliotecas especializadas para el análisis de datos y la optimización de redes, como NetworkX y pandas.

- Limpieza de datos

La limpieza de datos es una etapa crucial en el preprocesamiento, ya que garantiza que los datos utilizados sean precisos y completos. Los pasos específicos llevados a cabo incluyen:

- Detección y eliminación de valores faltantes: Se identificaron y corrigieron valores faltantes en las variables de población y coordenadas geográficas. En algunos casos, se realizaron imputaciones basadas en valores promedio o la estimación a partir de fuentes adicionales.
- Corrección de errores geográficos: Se verificó la precisión de las coordenadas geográficas, corrigiendo posibles errores mediante la comparación con fuentes geográficas confiables.
- Eliminación de duplicados: Se eliminaron registros duplicados para evitar redundancias que pudieran afectar la precisión del modelo.

- Transformación de datos

Para preparar los datos para su uso en el modelo, se llevaron a cabo varias transformaciones:

- Normalización de datos: Las variables de población fueron normalizadas para facilitar la comparación entre diferentes provincias y ciudades, asegurando que todas las variables tuvieran una escala comparable.
- Codificación geográfica: Las coordenadas geográficas fueron convertidas en formatos utilizables por los algoritmos de optimización, facilitando su integración en los modelos de simulación.
- Categorización de nodos: Las ciudades y provincias fueron categorizadas en función de su tamaño y su papel en la red de transporte, como nodos principales (ciudades grandes) y nodos secundarios (ciudades pequeñas y medianas).

- Preparación para el análisis

La preparación de datos para el análisis incluyó la creación de matrices de adyacencia y listas de aristas que representan las conexiones entre nodos en la red de transporte:

- Matriz de adyacencia: Se generó una matriz de adyacencia que representa las conexiones directas entre las capitales de provincia. Esta matriz es esencial para la simulación de flujos de transporte y la evaluación de la conectividad.
- Lista de aristas: Se creó una lista de aristas que detalla las conexiones entre nodos, incluyendo la distancia geográfica y otros atributos relevantes como la capacidad de transporte y los costos asociados.

- **Lenguajes de programación utilizados**

RStudio y el lenguaje R se utilizaron principalmente para la limpieza y el análisis exploratorio de datos. La capacidad de R para manejar grandes conjuntos de datos y realizar análisis estadísticos complejos fue esencial en la etapa inicial de preprocesamiento. Las funciones y bibliotecas específicas utilizadas incluyeron:

- Dplyr: Para la manipulación de datos y la creación de resúmenes estadísticos.
- ggplot2: Para la visualización de datos y la identificación de patrones y tendencias.

Python fue la herramienta principal para el desarrollo del modelo de optimización y la simulación. La elección de Python se basó en su versatilidad y la disponibilidad de bibliotecas especializadas. Las bibliotecas clave utilizadas fueron:

- pandas: Para la manipulación de datos y la creación de estructuras de datos eficientes.
- NetworkX: Para la creación y análisis de grafos, facilitando la implementación de algoritmos de optimización en redes de transporte.
- Matplotlib: Para la visualización de redes y resultados de simulación, permitiendo una representación clara de los patrones de conectividad y flujo.

- **Necesidad de Preprocesamiento**

- Manejo de datos faltantes e inconsistentes

El manejo de datos faltantes fue uno de los desafíos más significativos. En algunos casos, la falta de datos geográficos precisos requirió la interpolación de valores o el uso de fuentes adicionales para garantizar la precisión. También se encontraron inconsistencias en las denominaciones de ciudades y provincias, que se resolvieron mediante un proceso de estandarización de nombres.

- Exclusión de regiones no pertinentes

Dada la naturaleza del algoritmo y el enfoque en la península, fue necesario excluir las ciudades autónomas de Ceuta y Melilla, así como los archipiélagos (Islas Canarias y Baleares). Esta exclusión se justificó por la complejidad añadida que presentan estas regiones en términos de conectividad directa a la red peninsular y su impacto en los cálculos de flujo de transporte.

- Validación de datos

La validación de datos geográficos y de población se realizó mediante la comparación con fuentes oficiales y la verificación cruzada de diferentes conjuntos de datos. Este proceso ayudó a garantizar que los datos utilizados fueran confiables y representativos, reduciendo el riesgo de errores que pudieran afectar la precisión del modelo de optimización.

- **Resultados del Preprocesamiento**

- **Datos limpios y transformados**

El resultado del proceso de preprocesamiento fue un conjunto de datos limpio y transformado que se utilizó como base para la simulación y el análisis del modelo. Estos datos incluyeron variables normalizadas y geográficamente codificadas

- **Conectividad y representación de la red**

La creación de la matriz de adyacencia y la lista de aristas proporcionó una representación clara de la conectividad entre nodos en la red de transporte. Esto facilitó la implementación de algoritmos de optimización y permitió una evaluación precisa de la eficiencia del flujo de transporte en la red.

- **Preparación para la simulación**

Con los datos preprocesados, se pudo proceder a la simulación del modelo de optimización, utilizando los datos para configurar y ejecutar las simulaciones. Esta preparación fue crucial para asegurar que el modelo tuviera una base sólida de datos confiables y representativos para generar resultados precisos y valiosos.

PLANTEAMIENTO DEL PROBLEMA

Problemas de diseño de una red de transporte

El problema de diseño de una red de transporte (Network Design Problem, NDP, por sus siglas en inglés) es un desafío fundamental en la planificación y gestión de infraestructuras. Considerando la red como un grafo de nodos (poblaciones) y aristas (vías de comunicación), la esencia del problema radica en seleccionar un subgrafo dentro de una red ponderada que satisfaga la demanda de transporte punto a punto mientras minimiza los costos totales asociados. Este problema es de gran relevancia en situaciones del mundo real, donde la eficiencia y la efectividad de las redes de transporte son cruciales para el desarrollo económico y social. [24]

En términos generales, existen dos enfoques principales para abordar el NDP:

- **Soluciones Exactas [25]:**
 - Estos métodos buscan resolver el NDP de manera rigurosa y precisa.
 - Utilizan algoritmos matemáticos, como la programación lineal o la programación entera, para encontrar la solución óptima.
 - Sin embargo, estos enfoques son a menudo ineficientes para redes del mundo real a gran escala debido a la complejidad computacional.
- **Soluciones Heurísticas [7]:**
 - Los enfoques heurísticos se han vuelto más populares debido a su capacidad para proporcionar soluciones aproximadas eficientemente.
 - Estos métodos incluyen algoritmos evolutivos, algoritmos genéticos, búsqueda tabú y otros métodos de optimización basados en reglas más simples.
 - Aunque no garantizan la solución óptima, son capaces de abordar problemas del mundo real con un gran número de variables de diseño de manera más eficiente.

Cuando se trata de diseñar una red de transporte, la consideración de la tolerancia a fallos y el alto rendimiento se convierte en un aspecto crítico. La infraestructura de transporte debe ser capaz de hacer frente a eventos imprevistos como accidentes de tráfico, ataques terroristas o incluso condiciones meteorológicas extremas. Aquí, el concepto de "tolerancia a fallos" implica la capacidad de la red para mantener su funcionalidad incluso en presencia de perturbaciones.

Sin embargo, la tolerancia a fallos y el alto rendimiento vienen acompañados de costos más altos en términos de construcción y mantenimiento. Aquí es donde surge la necesidad de equilibrar estos aspectos clave:

- **Costo Total:**
 - Incluye los costos de construcción inicial y los costos de mantenimiento a lo largo del tiempo.

- **Tolerancia a Fallos:**
 - Implica la capacidad de la red para resistir y recuperarse de eventos inesperados.
- **Rendimiento:**
 - Se refiere a la eficiencia operativa y la capacidad de la red para satisfacer la demanda de transporte.

Por lo tanto, estos serán los aspectos en los que evaluaremos a nuestro modelo, comparando su desempeño con otros algoritmos ya existentes para encontrar la solución óptima ya que en la toma de decisiones de diseño, es esencial encontrar un equilibrio óptimo que satisfaga las necesidades de la red y de la sociedad en términos de costo, tolerancia a fallos y rendimiento.

Solución por algoritmos biológicos

A lo largo de la evolución biológica los seres vivos han ido optimizando sus redes de transporte, en un proceso natural de millones de años, tanto en lo que se refiere al transporte interno de nutrientes (sistemas vasculares de plantas y animales), como en sus patrones de desplazamiento externo (forrajeo de insectos sociales, senderos de migración de aves y animales, rutas de caza de depredadores). Por lo tanto, puede ser muy fructífero inspirarse en estas soluciones naturales que aparecen en la Biología, cuando se trata de diseñar redes de transporte por las que se desplacen de artefactos hechos por el hombre.

Por ejemplo, el algoritmo biológico de optimización de una colonia de hormigas (Ant Colony Optimization ACO, en inglés) [8] fue desarrollado observando como las hormigas adoptan un enfoque fascinante para encontrar la ruta más eficiente entre su colonia y una fuente de alimento. Inicialmente, estas hormigas exploran su entorno de manera aleatoria. Sin embargo, cuando una hormiga descubre comida, regresa a la colonia dejando un rastro de feromonas en su camino, incitando a otras hormigas a seguir dicho camino. Esto crea caminos de feromonas que tienden a ser muy eficientes. Este es un ejemplo de un algoritmo tipo “Swarm” [9].

Sin embargo, en la naturaleza hay una criatura única que exhibe propiedades biológicas singulares en sus sistemas de transporte internos y externos. Se trata de un moho mucilaginoso acelular llamado *Physarum Polycephalum* [10].

En su etapa vegetativa de plasmodio, este moho mucilaginoso es una célula única con muchos núcleos, que se alimenta de partículas microscópicas. Cuando busca su alimento, el plasmodio se propaga hacia las fuentes de partículas de alimentos, las rodea, secreta enzimas y digiere el alimento. Típicamente, el plasmodio forma una congregación de protoplasma que cubre la fuente de alimentos. Cuando varias fuentes de nutrientes están dispersas en el rango del plasmodio, esta forma una red de tubos protoplásmicos que conectan las masas de protoplasma en las fuentes de alimentos.

Durante su comportamiento de búsqueda de alimentos, el plasmodio conecta fuentes dispersas de nutrientes con una red de tubos protoplásmicos. La red protoplásmica está

optimizada para cubrir todas las fuentes de alimentos y proporcionar un transporte robusto y rápido de nutrientes y metabolitos en el cuerpo del plasmodio. El comportamiento de búsqueda de alimentos del plasmodio se puede interpretar como una computación, donde los datos se representan mediante configuraciones espaciales de atractivos y repelentes, y los resultados de la computación son la red protoplásmica formada por el plasmodio en los conjuntos de datos. Los problemas resueltos por el plasmodio de *Physarum polycephalum* incluyen la ruta más corta, la conexión eficiente de diferentes conjuntos de fuentes de alimentos, implementación de máquinas de modificación de almacenamiento, diagrama de Voronoi, triangulación de Delaunay, computación lógica y álgebra de procesos, entre otros.

En 2007 se propuso un algoritmo matemático del comportamiento morfológico de este hongo [11], y en 2012 se demostró que ese algoritmo converge hacia una ruta más corta en la red independientemente de la estructura inicial de la red o de la distribución inicial de masa [A, B].

A partir de estas referencias, en el presente trabajo, exploramos el algoritmo del *Physarum* para resolver un NDP en términos de costos, eficiencia y robustez. Empleamos el modelo de flujo para estimar el flujo de tráfico entre un par de ciudades. Con base en una demanda de viaje específica, utilizamos *Physarum* para simular el flujo de transporte entre las ciudades. Luego permitimos que el moho colonice todas las ciudades, desarrolle su red protoplásmica y se establezca en algún estado estable. El estado estable representa una solución del NDP.


Aplicaciones del algoritmo del Physarum Polycephalum

En 2010 se publicó un estudio [10] comparativo del algoritmo matemático y el desarrollo de este hongo específico, con el propósito de simular la red de metro de Tokio. Para la ejecución del experimento, se dispusieron porciones de avena, utilizada como fuente de alimento para el hongo, en correspondencia con las ubicaciones de las estaciones de metro en el mencionado sistema de transporte.



Desarrollo del hongo sobre Tokyo 0hrs


Posteriormente, el hongo fue posicionado en el centro del mapa, permitiéndose su desarrollo durante varias horas.



Desarrollo del hongo sobre Tokyo 5hrs, 8hrs, 16hrs y 26hrs

Los resultados revelaron que en un lapso relativamente breve, el hongo reprodujo de manera notablemente precisa la configuración de la red de metro que ingenieros y planificadores habían dedicado años en diseñar. Este experimento sirvió como catalizador para el desarrollo de algoritmos capaces de simular el crecimiento del hongo, los cuales se aplicaron posteriormente en diversos contextos.

Así, se llevó a cabo una simulación sobre el territorio de los Estados Unidos demostrando la versatilidad y aplicabilidad de dichos algoritmos en distintas situaciones geográficas.



Simulación de expansión del hongo Physarum mediante algoritmos de enjambre

La implementación de algoritmos derivados de este enfoque presenta notables beneficios, abarcando tanto consideraciones relacionadas con la eficiencia de costos como otros

aspectos destacados previamente expuestos. La capacidad de simular y modelar sistemas complejos a través de la inspiración biológica proporciona una herramienta valiosa para optimizar la planificación y el diseño en diversos campos.

Este enfoque no solo ofrece una perspectiva novedosa en la resolución de problemas, sino que también puede conducir a soluciones más eficientes y adaptativas en comparación con enfoques tradicionales. En consecuencia, la aplicación de estos algoritmos no solo ahorra recursos financieros, sino que también potencia la capacidad de abordar desafíos complejos de manera innovadora y efectiva.

MODELO MATEMÁTICO PARA EL HONGO PHYSARUM

Elementos del modelo

El organismo fúngico Physarum emplea estructuras tubulares denominadas hifas para facilitar su expansión. Estos conductos actúan como canales por los cuales el protoplasma se desplaza en dirección a diversas fuentes de nutrientes presentes en su entorno. En nuestro enfoque, conceptualizamos estas fuentes alimenticias como ciudades, abordándolas como nodos en nuestro análisis, que denotaremos:

$$N_1, \dots, N_n$$

donde "n" representa el número total de nodos en nuestra red. Las conexiones establecidas entre estos nodos se denotan como aristas

$$M_{ij},$$

las cuales exhiben características particulares que serán detalladas a continuación.

Para simular el flujo de pasajeros entre ciudades, podemos suponer que este volumen de personas se comporta como un fluido [18]. Para ser precisos, consideraremos que se comporta conforme a un modelo de fluido de Poiseuille [11], caracterizado por las siguientes propiedades:

- En los nodos
Cada nodo N_i tendrá una cualidad llamada presión p_i , con ella definimos el total de personas que salen de dicho nodo a todos los caminos que conectan con dicho nodo.
- En las aristas
Cada M_{ij} posee las siguientes características:
 - D_{ij} Medida del grosor del tubo, influirá en el volumen de fluido que pueda transportar el mismo. Su ecuación es:

$$D_{ij} = \frac{\pi \cdot a_{ij}^4}{8k}$$

donde a_{ij} es el radio del tubo y la k es la constante de viscosidad, la cual aproximamos a 1.

- L_{ij} : Medida del largo del tubo, a mayor tamaño de este como veremos más adelante, mayor costo de mantenimiento de este, a no ser que vaya secundado por un flujo muy alto.
- $(p_i - p_j)$: Se trata del diferencial de presiones que hay en cada extremo de la arista, cada uno de los operandos corresponde a la presión correspondiente a cada nodo

Con esto, teniendo en cuenta que estamos trabajando con un fluido de Poiseuille podemos describir cómo evolucionará el flujo entre los nodos con la siguiente ecuación, definida por la Ley de Flujo de Poiseuille:

$$Q_{ij} = \frac{D_{ij}}{L_{ij}} \cdot (p_i - p_j)$$

donde Q_{ij} denota el flujo dentro de la arista.

Ley de Conservación del Flujo

De acuerdo con la definición previa, los conductos se expanden conforme a las propiedades de un fluido de Poiseuille. Continuando con las características de este tipo de fluidos, se impone la condición de que la presión dentro de este sistema cerrado debe permanecer constante. En otras palabras, la suma de las presiones que abandonan un nodo debe ser igual a la suma de las presiones que ingresan en el mismo. Por lo tanto, tenemos:

$$\sum_{ij} Q_{ij} = 0$$

A partir de esto podemos deducir otros supuestos. Siendo N_1 el nodo origen y N_2 en el nodo destino, se establece que el flujo total que parte de este debe ser equivalente al que llega al nodo de origen, sin considerar los nodos intermedios a lo largo del trayecto. Esta condición puede expresarse mediante las siguientes ecuaciones:

$$\sum_i Q_{i1} = -I_0$$

donde $-I_0$ es el flujo (en negativo ya que está saliendo) del nodo origen.

$$\sum_i Q_{i2} = I_0$$

donde I_0 es el flujo (en positivo ya que está entrando) que llega al nodo destino.

Por lo tanto, de esas dos ecuaciones podemos despejar que:

$$\sum_i Q_{i1} + I_0 = 0$$

$$\sum_i Q_{i2} - I_0 = 0$$

De estos supuestos podemos calcular la ecuación de Poisson que sigue nuestra red,

Con esto tenemos todos los parámetros necesarios para el algoritmo. Primero, partiendo de un grafo, inicializamos todas las Q_{ij} como 1, para que, en la primera iteración, en base en las presiones definidas en cada nodo se actualicen los D_{ij} adaptándose a las necesidades de flujo de cada tubo, con el paso de las iteraciones, aquellos tubos que tengan Q_{ij} muy bajas,

irán decaendo hasta que desaparezcan, dejando así solo aquellos que de forma más eficiente conecten los nodos dentro de la red.

Función de Coste

La expansión tanto de un hongo como de una red de transporte implica un costo intrínseco de mantenimiento. En este contexto, introduciremos un nuevo parámetro denominado "Energía", que representará el costo asociado al mantenimiento de los conductos en nuestra red. Esta energía será proporcionada por el flujo que recorre el tubo en sí y estará relacionada con las características inherentes del mismo. De esta manera, definimos las nuevas propiedades de este parámetro.

- El flujo que atraviesa un conducto constituye la aportación energética destinada al mantenimiento temporal de dicho tubo. La cantidad de energía asignada en función del flujo puede expresarse como:

$$E_{ij} = |Q_{ij}|$$

donde E_{ij} es la energía asignada para M_{ij}

- Para determinar el consumo de energía asociado a un tubo, es esencial considerar sus características, ya que un tubo de dimensiones mayores implicará un costo superior. Por ende, la ecuación para el gasto energético se define como:

$$G(E_{ij}) = D_{ij} \cdot (L_{ij}^2) \cdot \theta$$

Tenemos que el consumo de energía es directamente proporcional a D_{ij} (el grosor del tubo) y L_{ij} (el largo del tubo) el cual elevamos al cuadrado para aumentar la penalización a aquellos tubos con mayor largo, además se añade un parámetro θ el cual nos permitirá plantear diferentes opciones de costo para comparar los grafos resultantes.

Con estas ecuaciones podemos calcular la evolución del parámetro D_{ij} durante los diferentes instantes de tiempo. El valor de Q_{ij}^{t+1} , se calculará como la diferencia entre el aporte energético dado por el flujo y el consumo de energía definido por la ecuación anterior. Esto sigue la siguiente ecuación:

$$\Delta Q_{ij}^{t+1} = |Q_{ij}^t - (D_{ij} \cdot L_{ij} \cdot \theta)| \times \Delta t$$

$$\frac{Q_{ij}^{t+1}}{dt} = |Q_{ij}^t - (D_{ij} \cdot L_{ij} \cdot \theta)|$$

Con estas ecuaciones obtenemos la función según la cual evoluciona Q_{ij} en el modelo. Si un tubo se extiende longitudinalmente mucho sin que su flujo aumente de forma proporcional, no podrá tener suficiente energía para mantenerse, por lo que con el tiempo acabará decaendo. Por otro lado, si el flujo que recibe un tubo es superior al costo su mantenimiento, aumentará el D_{ij} . Esta tendencia se mantendrá hasta que se alcance un estado de equilibrio y finalizará el algoritmo.

Eliminación de caminos en decadencia

Actualmente el algoritmo tiene el problema de que puede que existan caminos que se mantengan valores Q_{ij} muy cercanos a 0 antes de decaer. Por lo tanto, por razones de eficiencia, debemos definir un criterio según el cual se eliminen aquellos tubos que tengan un valor D_{ij}

Para ello definimos una constante δ tal que si:

$$D_{ij} < \delta \quad \longrightarrow \quad Q_{ij} = M_{ij} = 0$$

Al incorporar este enfoque, logramos acelerar el declive de un tubo que, de otra manera, habría requerido múltiples iteraciones para degradarse por sí mismo. Esto contribuye a reducir la carga computacional del algoritmo y acelera su resolución.

Criterio de parada

Finalmente decidimos cual será el momento en el que se finalizará el algoritmo, esto lo haremos a través de un parámetro α . Este criterio podemos definirlo de muchas formas, puede ser un número máximo de iteraciones, puede ser un tiempo máximo de ejecución o como definiremos los algoritmos descritos a continuación que se alcance un estado de equilibrio.

IMPLEMENTACIÓN DEL MODELO MATEMÁTICO

El Algoritmo de Múltiples Fuentes, inspirado en el comportamiento de crecimiento del moho mucilaginoso *Physarum polycephalum*, es un enfoque innovador para la optimización de redes de transporte. Este algoritmo parte de la premisa de iniciar la expansión desde múltiples nodos simultáneamente, replicando la forma en que *Physarum* conecta eficientemente diferentes fuentes de nutrientes en su entorno natural. La capacidad de iniciar el crecimiento desde varios puntos permite explorar exhaustivamente el espacio de soluciones y establecer una red de transporte que optimiza la conectividad y la eficiencia.

Justificación y Fundamento Teórico

- Principios biológicos aplicados

En la naturaleza, ***Physarum polycephalum*** expande su red protoplásmica desde múltiples fuentes hacia varios objetivos de manera simultánea. Este crecimiento se basa en la búsqueda eficiente de recursos, donde cada parte del moho actúa como una fuente independiente de expansión. Al adaptarse a las condiciones locales y globales del entorno, el moho forma una red optimizada que conecta fuentes de alimento dispersas.

- Aplicación en Redes de Transporte

El enfoque de múltiples fuentes es altamente beneficioso en la planificación de redes de transporte, especialmente cuando se necesita una cobertura rápida y amplia. Al inicializar la expansión en varios nodos del grafo, que representan ciudades o puntos críticos en la red de transporte, el algoritmo permite una exploración simultánea de rutas potenciales y una rápida identificación de las conexiones más eficientes. Esta característica es esencial para establecer rápidamente una red cohesiva que maximice la conectividad entre diferentes regiones.

Descripción del Algoritmo de Múltiples Fuentes

- Inicialización del Hongo en Cada Nodo

El algoritmo comienza con la inicialización de un "hongo" en cada nodo del grafo. Cada nodo actúa como una fuente de expansión, iniciando un proceso de crecimiento hacia nodos adyacentes. La configuración inicial se basa en:

- Selección de Nodos: Cada nodo del grafo, que puede representar ciudades, se configura para actuar como un punto de inicio del crecimiento. La selección se realiza considerando la importancia de cada nodo en términos de demanda de transporte.
- Condiciones de Inicio: Cada hongo (nodo) comienza su expansión con una presión inicial que refleja la demanda de transporte o la centralidad del nodo

en la red. Los nodos con mayor presión representan áreas con alta demanda y mayor conectividad necesaria.

- **Expansión Simultánea desde Múltiples Puntos**

Desde cada nodo inicial, el algoritmo simula la expansión del moho hacia los nodos vecinos de acuerdo con las reglas establecidas por el marco teórico:

- **Evaluación de Conexiones:** Cada nodo evalúa las posibles conexiones con nodos vecinos basándose en criterios como la distancia geográfica y la demanda de transporte. Se favorecen las conexiones que minimizan los costos de construcción y maximicen la eficiencia del flujo.
- **Propagación de Presión:** La presión del nodo inicial se propaga a través de las conexiones establecidas, incrementando la presión en los nodos vecinos y promoviendo la expansión hacia otras partes de la red.

- **Influencia de Nodos con Mayores Presiones**

Los nodos con mayores presiones, que representan ciudades con alta demanda de transporte, tienen una influencia significativa en la expansión de la red:

- **Rutas de Larga Distancia:** Estos nodos tienden a proyectar un mayor número de rutas hacia nodos más lejanos, facilitando la conectividad entre regiones distantes. Actúan como centros de conectividad, estableciendo rutas que cruzan grandes distancias y uniendo diferentes partes de la red.
- **Optimización de Conectividad:** Al expandirse hacia nodos más lejanos, los nodos con alta presión ayudan a crear una red que equilibra la conectividad local y global, asegurando que tanto las rutas principales como las secundarias sean eficientes.

- **Contribución de Nodos con Menores Presiones**

Por otro lado, los nodos con menores presiones tienden a mantener un número limitado de conexiones, principalmente con nodos cercanos:

- **Formación de Clústeres Locales:** Estos nodos contribuyen a la formación de clústeres locales, aumentando la densidad de conexiones en áreas específicas. Esto promueve una red con alta conectividad en zonas locales, asegurando que los usuarios en estas áreas tengan fácil acceso a la red principal.
- **Red de Apoyo:** Aunque no establecen muchas conexiones de larga distancia, estos nodos proporcionan soporte esencial para la conectividad local, facilitando el acceso a la red más amplia.

Limitaciones y Desafíos

- **Complejidad Computacional**

La expansión simultánea desde múltiples nodos puede llevar a una complejidad computacional significativa, especialmente en redes grandes y complejas. El coste de este algoritmo lo calcularemos a en apartados siguientes

- **Conectividad de Subgrafos**

Existe el riesgo de que queden regiones desconectadas o subgrafos aislados si la expansión no se gestiona adecuadamente. Es necesario implementar estrategias para asegurar que todos los nodos estén conectados de manera efectiva a la red principal, evitando la fragmentación.

Análisis de Complejidad temporal y espacial del algoritmo

- **Complejidad Espacial**

La complejidad espacial del código se refiere a la cantidad de memoria que utiliza el algoritmo en función del tamaño de su entrada. En este código, los componentes principales que contribuyen a la complejidad espacial son las clases `Nodo` y `Camino`, así como las estructuras de datos utilizadas para almacenar los nodos y caminos.

1. Clase `Nodo`:

- Cada nodo almacena su nombre, coordenadas, presión, permanencia, y un contador de conexiones.
- Asumiendo que cada nodo ocupa espacio proporcional a sus atributos, el espacio utilizado por todos los nodos es $O(N)$, donde N es el número de nodos.

2. Clase `Camino`:

- Cada camino almacena referencias a los nodos de inicio y fin, así como varios atributos como el ancho, presión, longitud, flujo, energía y gasto.
- Como cada camino conecta dos nodos, el número máximo de caminos en un grafo completo es $O(N^2)$.

3. Estructuras de Datos:

- Lista de nodos: Almacena (N) nodos.
- Lista de caminos: Almacena hasta $O(N^2)$ caminos en el peor caso (grafo completo).

Es decir, la complejidad espacial del código predominante viene dada por la lista de caminos ya que esta la que conlleva un mayor coste espacial, lo que lleva a una complejidad espacial total de $O(N^2)$.

Sin embargo a la hora de evaluar un algoritmo de este tipo es más relevante conocer que orden de complejidad temporal maneja ya que este tipo de algoritmos suele tener que tratar con grandes conjuntos de nodos y es esencial que sea rápido a la hora de procesar una solución.

- Complejidad Temporal

La complejidad temporal se refiere al tiempo de ejecución del algoritmo en función del tamaño de su entrada. Vamos a analizar cada función principal del código para determinar su contribución a la complejidad temporal total.

1. Inicialización de `Nodo`:

- Crear un nodo es una operación constante, $O(1)$.

2. Inicialización de `Camino`:

- La inicialización incluye la creación de un camino y la llamada a `calcular\_distancia`, lo cual es una operación $O(1)$ si asumimos que el cálculo de la distancia es constante para dos coordenadas.

3. Función `crear\_grafo\_completo`:

- Inicializa (N) nodos en $O(N)$.
- Crea todos los caminos posibles entre los nodos, resultando en $\backslash(O(N^2) \backslash)$ operaciones, ya que se itera sobre todos los pares de nodos.

4. Función `calcular\_ancho\_camino`:

- Cada llamada a `calcular\_ancho\_camino` realiza operaciones constantes: cálculo del ancho, energía, flujo y gasto, y verificaciones condicionales. La complejidad temporal es $O(1)$.

5. Función `eliminar\_conexion`:

- Actualiza las conexiones de dos nodos. La operación es constante, $O(1)$.

6. Función `actualizar\_presiones`:

- Itera sobre todos los caminos. La complejidad es $O(N^2)$ en el peor caso (grafo completo, el cual es el caso en nuestro estudio).

7. Función `dibujar\_grafo`:

- Añade (N) nodos al grafo y $O(N^2)$ aristas en el peor caso.
- Dibuja el grafo, lo que podría ser complejo pero, en términos de contribución computacional, consideramos las operaciones sobre los nodos y caminos, resultando en $O(N^2)$.

8. Bucle Principal (MAIN):

- Ejecuta hasta `iteraciones` veces. En cada iteración:
- Llama a `dibujar\_grafo`, $O(N^2)$.

- Itera sobre todos los caminos para llamar a `calcular\_ancho\_camino` y potencialmente eliminar caminos, $O(N^2)$.
- Llama a `actualizar\_presiones`, $O(N^2)$.

En el peor caso, para cada iteración en el bucle principal, se realizan operaciones $O(N^2)$. Por lo tanto tenemos que

Posibles Mejoras

Una posible mejora significativa en el algoritmo sería implementar la paralelización de los cálculos. Dado que el algoritmo realiza operaciones similares e independientes para cada camino, existe un alto potencial para aprovechar el procesamiento concurrente. Actualmente, el cálculo de propiedades de los caminos como ancho, presión, flujo, energía y gasto se realiza de manera secuencial. Al paralelizar estos cálculos, cada camino podría ser procesado simultáneamente en distintos hilos de ejecución o procesos.

- Detalles de la Mejora

Cada camino en la red se evalúa y actualiza de manera independiente en términos de ancho, presión y flujo. Este tipo de independencia hace que los cálculos sean ideales para paralelización, ya que no existe dependencia directa entre los resultados de las operaciones en diferentes caminos durante una iteración.

Al distribuir los cálculos entre múltiples núcleos de CPU o en un entorno de computación distribuida, el tiempo de ejecución para procesar todos los caminos puede reducirse considerablemente. Si, por ejemplo, la complejidad actual es $O(N^2)$, donde (N) es el número de nodos, el uso de paralelización podría reducir el tiempo de ejecución efectivo, acercándolo a $O(N^2 / P)$, donde (P) es el número de procesadores disponibles.

En redes grandes con un número considerable de nodos y caminos, la paralelización permite que el algoritmo escale de manera más efectiva, manteniendo la eficiencia incluso a medida que la red crece en tamaño. Se puede dividir el conjunto de caminos en bloques que se asignen a diferentes hilos o procesos. Cada hilo o proceso calcularía las propiedades (ancho, flujo, energía, gasto) de su bloque de caminos de forma concurrente.


RESULTADOS

Comparativa con diferentes parámetros


Para determinar los parámetros óptimos del modelo de optimización de redes de transporte basado en el comportamiento del moho mucilaginoso *Physarum polycephalum*, procedemos a ejecutar el algoritmo bajo una variedad de valores del parámetro omega. El objetivo de esta evaluación es observar cómo diferentes configuraciones de influyen en la estructura y eficiencia de la red resultante, y así identificar los valores que mejor se ajusten a nuestras necesidades de balance entre costo, eficiencia y robustez.

La elección del valor de omega afecta directamente la penalización por costos de mantenimiento en el modelo, impactando en la redundancia y longitud total de las rutas en la red. En nuestras simulaciones, se exploraron seis valores distintos de para capturar una amplia gama de comportamientos posibles

OMEGA = 0.3, 0.5



Resultado simulación para omega=0.3



Resultado simulación para omega=0.5

Los grafos obtenidos al ejecutar el algoritmo con valores de omega de 0.3 y 0.5 revelan varias dinámicas interesantes en la configuración de la red de transporte, especialmente en relación a la influencia de los nodos con presiones demográficas elevadas y la formación de clústeres hiperconectados.

Tanto en el caso de omega 0.3 como en el de omega 0.5, el algoritmo se ve significativamente afectado por la presencia de nodos con alta presión demográfica, particularmente Madrid. La gran población y la centralidad de Madrid lo convierten en un nodo crítico que puede sostener conexiones con otros nodos a largas distancias. Esta capacidad refleja la tendencia del algoritmo a priorizar conexiones desde nodos con alta demanda de transporte. Sin embargo, esto también puede señalar una limitación del

algoritmo para mantener adecuadamente conexiones en ciudades con menor presión demográfica, que no reciben la misma atención o inversión en infraestructura.

En ambos grafos se observa la formación de clústeres de nodos hiperconectados, principalmente en las regiones del centro y noreste de España. Este patrón es atribuible a la proximidad geográfica entre las ciudades en estas áreas, facilitando la creación de una infraestructura densa y bien conectada sin incurrir en altos costos adicionales.

- **Centro del país:**

A pesar de que las ciudades en Castilla y León no poseen grandes centros de población, se forma un clúster denso de transporte debido a la proximidad entre estas ciudades. Esta cercanía permite la construcción de numerosas rutas redundantes que, aunque aumentan la robustez de la red, no conllevan altos costos debido a la corta distancia entre nodos.

- **Norte y Este del país:**

Estas regiones presentan una combinación favorable de alta densidad poblacional y proximidad geográfica entre ciudades. Esto resulta en la formación de clústeres de transporte con una alta redundancia de rutas, que optimiza tanto la eficiencia del transporte como la robustez de la red. La proximidad permite que las rutas sean cortas y efectivas en cuanto a costo, facilitando un flujo de transporte eficiente

Las regiones del noroeste y el sur de España muestran patrones de conectividad menos densos y más dispersos en comparación con el centro y noreste, reflejando diferentes desafíos en términos de presión demográfica y distancia entre nodos.


- **Noroeste del país:**

Aunque Galicia y Asturias tienen una proximidad geográfica que podría favorecer la interconexión, la baja densidad de población en estas áreas limita la capacidad de formar clústeres de transporte robustos. El algoritmo refleja esta limitación al presentar una red con menos conexiones y redundancia, ya que la presión demográfica no es suficiente para justificar la creación de una infraestructura densa.


- **Sureste del país:**

En contraste, Andalucía y Extremadura presentan ciudades con alta presión demográfica, como Sevilla y Málaga. Sin embargo, la dispersión geográfica entre estas ciudades significa que las distancias entre nodos importantes son mayores. Esto resulta en la necesidad de un mayor esfuerzo y costo para mantener una red de transporte eficiente. No obstante, para los valores de omega analizados, existe cierta redundancia en las conexiones en esta zona, apoyada por Madrid, que actúa como un nodo central conectando estas principales ciudades del sur.

OMEGA = 0.6, 0,7



Resultado simulación para omega=0.6



Resultado simulación para omega=0.7

Los grafos obtenidos al ejecutar el algoritmo con valores de omega de 0.3 y 0.5 nos muestran como la tendencia de que centros de población como Madrid se impongan al resto de nodos sigue siendo notable y como a pesar de aumentar el costo de mantener estas conexiones siguen siendo capaces de crear y mantener caminos con nodos a grandes distancias. Es relevante ver como para omega = 0.7 ha aparecido la primera desconexión del grafo principal, en este caso en Galicia que más adelante vamos a comentar

Vemos como la hiperconectividad que podíamos apreciar en ejecuciones anteriores se ha visto reducida en gran medida. A continuación, evaluamos como las diferentes regiones que habíamos determinado anteriormente han evolucionado con los aumentos de costos de mantenimiento

- **Centro del país:**

Castilla y León que antes gozaba de unos niveles muy altos de redundancia ha perdido gran parte de estos, debido a que como comentamos anteriormente, sus ciudades no tienen mucha presión demográfica. Siguen teniendo buena conectividad, pero principalmente sostenida por las conexiones con Madrid.

- **Norte y Este del país:**

Estas dos regiones han mantenido la práctica totalidad de la redundancia en sus conexiones, esta región, debido a que posee todas las características favorables, proximidad entre nodos y gran acumulación de población veremos cómo es capaz de mantener sus clústeres de transporte

- **Noroeste y Sur de país:**


Las regiones del noroeste y el sur de España, que en ejecuciones anteriores ya sufrían a la hora de mostrar un grado aceptable de conectividad debido a sus

problemas geográficos y poblacionales, vemos como su problemática se ha agravado, tanto es así que para un omega de 0.7 la comunidad de Galicia posee varias ciudades desconectadas. Tal y como habíamos determinado anteriormente esta ejecución ya no será válida

En contraste, en Andalucía y Extremadura, aunque los costos de mantenimiento y creación de conexiones han aumentado, los caminos existentes no han cambiado significativamente en comparación con los resultados obtenidos con valores de omega más bajos. Esto se debe a la misma razón mencionada anteriormente: esta región tiene ciudades muy dispersas entre sí, pero con grandes centros poblacionales. Esta dispersión limita la creación de una gran variedad de rutas entre los nodos, a diferencia de lo que ocurre en el noreste, pero permite mantener un número decente de conexiones.

A continuación, a pesar de que ya hemos comprobado que con un omega = 0.7 aparecen regiones desconectadas de la red principal vamos a continuar aumentando el costo para ver como las otras regiones evolucionan.

OMEGA = 1



Resultado simulación para omega=1

Los grafos obtenidos al ejecutar el algoritmo con omega = 1 de nos muestran ofrecen datos muy interesantes. En esta ejecución, se observa claramente cómo la región de Galicia ha quedado completamente desconectada, debido principalmente a su baja densidad poblacional y la dispersión de sus nodos respecto al resto del conjunto. Este fenómeno resalta la desconexión de Galicia en comparación con otras regiones.

Adicionalmente, se destaca una tendencia consistente observada con otros valores de omega: la región central y noreste de España mantiene una fuerte interconexión y redundancia. Al desglosar estos resultados por comunidades autónomas, se obtienen los siguientes hallazgos:

- **Castilla y León:**

Esta comunidad autónoma se caracteriza por tener núcleos de población pequeños, pero muy próximos entre sí. Esta proximidad facilita la creación y el mantenimiento de rutas entre ellos de manera económica, resultando en una red eficiente de conexiones a corto plazo.

- **País Vasco:**

Esta región posee condiciones óptimas para el algoritmo utilizado, dado que sus centros de población son grandes y están situados a distancias cortas unos de otros. Esta configuración permite obtener una red de interconexiones muy eficiente, reflejando una alta densidad de conexiones internas.

- **Aragón:**

En esta comunidad, Zaragoza desempeña un papel similar al de Madrid en el contexto nacional. Zaragoza se convierte en el nodo central que conecta a todos los nodos dentro de la comunidad con los de otras comunidades. Aunque existen otras conexiones, como las de Huesca con Barcelona, Zaragoza se destaca como el principal centro de interconexión.

- **Cataluña:**

La principal conexión en Cataluña es Barcelona, que actúa como el nodo que se conecta con el resto de España. Desde Barcelona, se establecen conexiones con otros nodos dentro de la comunidad, configurando una red de distribución que centraliza el tráfico en este nodo principal antes de distribuirlo internamente.

- **Comunidad Valenciana:**

Valencia presenta una situación análoga a la de Cataluña. Valencia, como nodo principal, establece conexiones con otras regiones de España y sirve de base para la red interna de conexiones que enlaza los demás nodos de la comunidad.

- **Andalucía:**

Se observa una tendencia a mantener pocas conexiones de larga distancia, predominando las conexiones con Madrid. No obstante, se genera una red relevante de conexiones radiales entre las principales urbes de la comunidad y poblaciones más pequeñas, configurando un sistema de transporte regional que prioriza la centralización en grandes núcleos antes de extenderse a áreas menos pobladas.


- **Extremadura:**

Esta región presenta un caso notable que ilustra la dinámica de interconexión en áreas sin nodos poblacionalmente relevantes. Cáceres se conecta principalmente con Madrid, mientras que Badajoz se enlaza con Sevilla. Estas dos ciudades, sin embargo, permanecen desconectadas entre sí. Este patrón se debe a que las conexiones mencionadas no son mantenidas por las propias ciudades, sino que provienen de los grandes nodos regionales a los que están vinculadas, reflejando una dependencia de nodos más importantes para su conectividad externa.

Como podemos ver, la evaluación de las conexiones en estas comunidades autónomas revela un panorama variado, donde la densidad poblacional y la proximidad entre nodos juegan roles cruciales en la configuración y eficiencia de las redes de interconexión. Cada región presenta características particulares que influyen en su conectividad, desde la centralización en grandes nodos hasta la dependencia de centros de población externos para mantener sus rutas de comunicación.

OMEGA = 1.5

Por último, vamos a aumentar el valor de omega para ver cuáles son los principales nodos comunicadores del grafo y ver que subgrafos se crean



Resultado simulación para omega = 1.5

En este análisis, se puede observar claramente que Madrid actúa como el nodo principal, con la capacidad de generar conexiones con prácticamente todos los nodos del grafo sin que la distancia entre ellos sea una limitante significativa.

- **Madrid:**

Gracias a su centralidad y capacidad de conexión, Madrid se posiciona como el nodo principal que facilita la comunicación con la mayoría de los nodos en el grafo. Su influencia se extiende a varias regiones, lo que le permite mantener un alto grado de conectividad con diversas áreas, independientemente de la distancia.

- **Castilla y León:**

En esta región, se evidencia que los nodos dependen significativamente de Madrid, especialmente cuando se consideran costos elevados de conexión. La proximidad a la capital resulta beneficiosa, permitiendo a estos nodos optimizar su conectividad aprovechando las rutas establecidas a través de Madrid.

- **País Vasco:**

Esta comunidad mantiene una notable interconectividad interna, lo que sugiere la estabilidad de su subred. Los nodos dentro del País Vasco están fuertemente conectados entre sí, proporcionando una red robusta que facilita la comunicación interna sin depender excesivamente de nodos externos.

- **Cataluña:**

En Cataluña, Barcelona se destaca como el nodo principal, actuando como el centro de conexión de la región. Aunque Cataluña se mantiene desconectada del resto del grafo en términos generales, existe una estructura de conexiones radiales que vincula los nodos internos con Barcelona, creando una red eficiente dentro de la comunidad.

- **Comunidad Valenciana:**

Similar a Cataluña, la Comunidad Valenciana presenta una configuración radial que parte de Valencia. Sin embargo, a diferencia de Cataluña, esta región mantiene conexiones con el resto del grafo principalmente a través de Madrid, lo que le permite integrarse en la red más amplia.

- **Andalucía:**

Este caso es especialmente relevante, ya que Andalucía demuestra una buena interconectividad interna gracias a sus nodos de mayor población. Además, Andalucía se mantiene conectada con el resto del grafo a través de sus enlaces con Madrid, lo que facilita tanto la comunicación interna como la integración con otras regiones.

En conclusión, el análisis muestra que Madrid se establece como un nodo central indispensable en la red de conexiones, proporcionando una conectividad amplia y eficiente. Otras regiones, como Cataluña y la Comunidad Valenciana, desarrollan estructuras de conexión radial centradas en sus principales ciudades, mientras que comunidades como el

País Vasco y Andalucía presentan una fuerte interconectividad interna, complementada por sus conexiones con nodos clave como Madrid.

Comparativa con la red actual

Para comparar la efectividad del modelo creado lo vamos a comparar el siguiente mapa de la red ferroviaria española, realizado en 2015. Las conexiones intrarregionales están resaltadas por un color cada región y las conexiones interregionales están resaltadas en naranja



Mapa Ferroviario actual agrupado por regiones

Para llevar a cabo esta comparación, procederemos a analizar las diferencias y similitudes por regiones. Este enfoque nos permitirá identificar en qué condiciones el algoritmo desarrollado imita, mejora o no alcanza el desempeño de la red actual. Evaluaremos el comportamiento del algoritmo en distintas circunstancias y cómo se adapta a las características únicas de cada región.

La metodología utilizada para evaluar la calidad de la red en una región se basará en dos aspectos fundamentales: la conectividad intrarregional y la conectividad interregional.

- Conectividad Intraregional:

Este criterio mide el grado en que los nodos dentro de una misma región, definida como una comunidad autónoma, están conectados entre sí. Específicamente, se

cuantificará el número de caminos que unen nodos ubicados dentro de la misma comunidad autónoma, lo que refleja la cohesión interna y la eficiencia de la red dentro de la región. Un alto nivel de conectividad intrarregional indica una red bien integrada que facilita el movimiento y la comunicación entre diferentes puntos de la región sin depender de conexiones externas.

- **Conectividad Interregional:**

Este criterio evalúa la extensión de las conexiones entre los nodos de una región y los nodos situados fuera de dicha región. Se cuantificará el número de caminos que enlazan nodos dentro de una comunidad autónoma con nodos en otras comunidades autónomas. Este aspecto es crucial para determinar la accesibilidad de la región en un contexto más amplio, reflejando cómo se inserta en la red nacional y su capacidad para interactuar con otras regiones.

Ambos criterios serán utilizados para calificar la calidad de la red en cada región, permitiendo una comprensión detallada de la eficiencia de las conexiones tanto dentro de cada comunidad autónoma como entre distintas comunidades.

Vemos como la hiperconectividad que podíamos apreciar en ejecuciones anteriores se ha visto reducida en gran medida.

A continuacion y en base a los criterios mencionados anteriormente, analizamos la red ferroviaria actual

- **Región Noroeste (Galicia y Asturias):**

- Número de Ciudades: 5
- Conexiones intrarregionales: 5
- Conexiones interregionales: 4

En la región noroeste, compuesta por Galicia y Asturias, la red ferroviaria conecta cinco ciudades internamente con cinco enlaces, lo que sugiere una cohesión moderada dentro de la región. Adicionalmente, existen cuatro conexiones interregionales que permiten la comunicación con otras regiones, lo que indica una integración razonable con la red ferroviaria nacional.

- **Región Norte (Cantabria, País Vasco, Navarra y La Rioja):**

- Número de ciudades: 6
- Conexiones intrarregionales: 5
- Conexiones interregionales: 6

La región norte, que incluye Cantabria, el País Vasco, Navarra y La Rioja, cuenta con seis ciudades interconectadas por cinco enlaces intrarregionales. Además, tiene seis conexiones interregionales, lo que refleja un buen equilibrio entre la cohesión interna y la conectividad externa, permitiendo una interacción efectiva tanto dentro de la región como con el resto del país.

- **Región Noreste (Aragón y Cataluña):**

- Número de ciudades: 7
- Conexiones intrarregionales: 9
- Conexiones interregionales: 5

En la región noreste, que abarca Aragón y Cataluña, la red ferroviaria muestra una sólida estructura interna con nueve conexiones entre siete ciudades. Esto indica una fuerte cohesión y redundancia dentro de la región. La red también incluye cinco conexiones interregionales, facilitando la comunicación con otras áreas y mostrando una integración adecuada con la red nacional.

- **Región Centro Norte (Castilla y León):**

- Número de ciudades: 8
- Conexiones intrarregionales: 9
- Conexiones interregionales: 10

Castilla y León, en el centro norte, tiene una red que conecta ocho ciudades con nueve enlaces internos. Esta red bien desarrollada facilita una buena conectividad interna. Además, con diez conexiones interregionales, la región se muestra bien integrada con el resto del país, proporcionando una alta capacidad de comunicación y transporte entre diferentes regiones.

- **Región Centro Sur (Madrid y Castilla-La Mancha):**

- Número de ciudades: 5
- Conexiones intrarregionales: 6
- Conexiones interregionales: 12

La región centro sur, que incluye Madrid y Castilla-La Mancha, presenta una fuerte integración con la red nacional, evidenciada por sus 12 conexiones interregionales. Las seis conexiones intrarregionales que unen cinco ciudades reflejan una buena cohesión interna, aunque la mayor parte del tráfico se centra en Madrid, que actúa como un nodo central de la red ferroviaria.

- **Región Este (Comunidad Valenciana y Murcia):**

- Número de ciudades: 4
- Conexiones intrarregionales: 3
- Conexiones interregionales: 7

En la región este, que comprende la Comunidad Valenciana y Murcia, la red ferroviaria conecta cuatro ciudades con tres enlaces internos, lo que indica una conectividad intrarregional moderada. Con siete conexiones interregionales, la región muestra una buena integración con la red ferroviaria nacional, facilitando el acceso y la movilidad hacia otras áreas del país.

- **Región Oeste (Extremadura):**

- Número de ciudades: 2
- Conexiones intrarregionales: 1
- Conexiones interregionales: 3


Extremadura, en el oeste, tiene una red ferroviaria limitada, con solo dos ciudades conectadas por un único enlace interno. Sin embargo, cuenta con tres conexiones interregionales, lo que sugiere que, a pesar de la baja conectividad interna, la región está relativamente bien conectada con el resto del país, permitiendo alguna interacción externa.

- **Región Sur (Andalucía):**

- Número de ciudades: 6
- Conexiones intrarregionales: 7
- Conexiones interregionales: 3

En Andalucía, la red ferroviaria muestra una buena cohesión interna, con siete conexiones que unen seis ciudades, reflejando una sólida estructura intrarregional. No obstante, las tres conexiones interregionales indican una menor integración con la red nacional en comparación con otras regiones, lo que podría limitar la movilidad externa.

A continuación, realizamos el mismo análisis para la red generada por algoritmo propuesto en el estudio. Debido a que han resultado regiones o regiones desconectadas del grafo, no tendremos en cuenta aquellos nodos que no estén conectados al grafo principal



Mapa Ferroviario generado por el algoritmo agrupado por regiones con Omega = 1.3

- **Región Noroeste (Galicia y Asturias):**

No se analizará esta región ya que ha quedado completamente desconectada en el grafo generado por el algoritmo. Debido a esta desconexión, el modelo actual ofrece una solución superior en esta área, proporcionando una mejor cobertura y conectividad.

- **Región Norte (Cantabria, País Vasco, Navarra y La Rioja):**

- Número de ciudades: 6
- Conexiones intrarregionales: 7
- Conexiones interregionales: 10

En la región norte, que incluye Cantabria, el País Vasco, Navarra y La Rioja, el algoritmo ha conectado seis ciudades con siete enlaces intrarregionales, mejorando la cohesión interna en comparación con la red actual. Además, ha establecido diez conexiones interregionales, incrementando significativamente la integración con la red nacional y facilitando una mayor interconectividad con otras regiones.

- **Región Noreste (Aragón y Cataluña):**

- Número de ciudades: 7
- Conexiones intrarregionales: 5
- Conexiones interregionales: 6

Para la región noreste, abarcando Aragón y Cataluña, el algoritmo ha generado cinco conexiones intrarregionales entre siete ciudades, lo que sugiere una cohesión interna moderada. Las seis conexiones interregionales muestran una integración razonable con la red más amplia, permitiendo la comunicación efectiva con otras regiones.

- **Región Centro Norte (Castilla y León):**

- Número de ciudades: 8
- Conexiones intrarregionales: 7
- Conexiones interregionales: 6

En Castilla y León, el algoritmo ha conectado ocho ciudades con siete enlaces intrarregionales. Sin embargo, algunas ciudades están desconectadas del resto de la región, lo que penaliza la cohesión interna. A pesar de esto, las seis conexiones interregionales facilitan la integración con el nodo principal y, por ende, con la red nacional, lo que mitiga parcialmente los efectos de la desconexión interna.

- **Región Centro Sur (Madrid y Castilla-La Mancha):**

- Número de ciudades: 5
- Conexiones intrarregionales: 5
- Conexiones interregionales: 22

La región centro sur, que incluye Madrid y Castilla-La Mancha, muestra una gran conectividad interregional con 22 enlaces, la mayoría de los cuales llegan directamente a Madrid. Esto refleja una fuerte centralización en la capital, permitiendo que Madrid actúe como un nodo principal de conexión a nivel nacional. Las cinco conexiones intrarregionales proporcionan una cohesión interna adecuada, aunque la centralización en Madrid es notablemente alta.

- **Región Este (Comunidad Valenciana y Murcia):**

- Número de ciudades: 4
- Conexiones intrarregionales: 4
- Conexiones interregionales: 5

En la región este, que abarca la Comunidad Valenciana y Murcia, el algoritmo ha establecido cuatro conexiones intrarregionales entre cuatro ciudades, mejorando la cohesión interna. Las cinco conexiones interregionales facilitan la integración de la región con el resto del país, permitiendo una comunicación eficaz con otras áreas.

- **Región Oeste (Extremadura):**

- Número de ciudades: 2
- Conexiones intrarregionales: 1
- Conexiones interregionales: 3

Extremadura, en el oeste, sigue mostrando una conectividad interna limitada con solo un enlace que conecta dos ciudades. Sin embargo, con tres conexiones interregionales, la región se mantiene integrada con la red nacional, proporcionando algunas vías para la interacción externa a pesar de la baja cohesión interna.

- **Región Sur (Andalucía):**

- Número de ciudades: 6
- Conexiones intrarregionales: 10
- Conexiones interregionales: 7

En Andalucía, el algoritmo ha logrado una excelente cohesión interna, con diez conexiones que unen seis ciudades, superando la red actual en términos de conexiones intrarregionales. Las siete conexiones interregionales reflejan una integración efectiva con la red nacional, facilitando tanto la conectividad interna como la comunicación con otras regiones.

Para completar el análisis del algoritmo, es fundamental considerar la distancia total acumulada por los caminos en la red generada. En este modelo, la longitud total de las conexiones es de 13.545,990 km. Es importante destacar que esta cifra es una estimación basada en la distancia en línea recta entre los nodos, lo que puede diferir de la realidad en la infraestructura de la red.

En comparación, la red ferroviaria actual tiene una extensión total de 11.872,8 km. Esta medida refleja la longitud efectiva de las vías, que incluye las rutas y las infraestructuras existentes, las cuales no siempre siguen un trayecto recto debido a diversas limitaciones geográficas y de diseño.

Propuesta de mejora

El Algoritmo de Múltiples Fuentes, descrito en el modelo matemático, inicia con la expansión simultánea desde varios nodos, lo que permite explorar rápidamente el espacio de soluciones y proporciona una cobertura amplia de la red de transporte. Sin embargo, esta estrategia puede llevar a regiones desconectadas o ineficiencias debido a la posible redundancia de caminos. El Algoritmo de Fuente Única (Single Source Algorithm) ofrece una alternativa que puede mitigar estos problemas, proporcionando una forma más controlada y dirigida de optimizar la red desde un nodo central, y reduciendo la probabilidad de duplicar rutas innecesarias.

Justificación de la mejora

El Algoritmo de Fuente Única se basa en la expansión a partir de un nodo central, permitiendo un enfoque más gradual y dirigido en la construcción de la red de transporte. Este enfoque puede mejorar la eficiencia del algoritmo de múltiples fuentes al:

- **Reducir la redundancia de rutas:** Al expandirse desde un solo nodo, el algoritmo minimiza la posibilidad de generar rutas redundantes entre nodos que ya están conectados, optimizando la utilización de recursos y mejorando la eficiencia general de la red.
- **Asegurar la conectividad:** La expansión controlada permite asegurar que todas las regiones estén conectadas al nodo central, evitando la desconexión de subgrafos y asegurando una red cohesiva y funcional.
- **Mejorar la escalabilidad:** El enfoque de una sola fuente puede ser más escalable en redes grandes, donde la expansión desde múltiples nodos simultáneamente podría volverse ineficiente o difícil de manejar.

Descripción del Algoritmo de Fuente Única

- Selección del Nodo Central:

El primer paso en la implementación del Algoritmo de Fuente Única es la selección del nodo central desde el cual se iniciará la expansión. La elección de este nodo es crítica y se basa en varios criterios:

- **Población:** Se elige una ciudad con una alta densidad de población, que típicamente tiene una mayor demanda de transporte.
- **Centralidad geográfica:** El nodo debe estar estratégicamente ubicado para maximizar la conectividad con otras regiones.

- **Importancia económica:** La selección puede basarse en la importancia económica del nodo, asegurando que el núcleo de la red de transporte sirva como un centro vital para el movimiento de personas y mercancías.

Para el caso de estudio en España, Madrid es una opción natural como nodo central debido a su alta población, ubicación central en la península, y su papel como capital y principal hub económico del país.

- **Expansión Gradual desde el Nodo Central:**

Desde el nodo central seleccionado, el algoritmo se expande gradualmente hacia los nodos adyacentes. Este proceso implica:

- **Evaluación de Conexiones:** Se evalúan las conexiones entre el nodo central y los nodos adyacentes basándose en la demanda de transporte y la distancia geográfica. Se priorizan las conexiones que ofrecen la mayor eficiencia en términos de costo y conectividad.
- **Actualización de la Red:** A medida que se establecen conexiones, la red se actualiza para reflejar la nueva estructura, asegurando que cada nuevo nodo esté correctamente integrado en la red existente.

- **Propagación de la Expansión:**

Una vez que se han establecido las primeras conexiones desde el nodo central, el algoritmo continúa expandiéndose, siguiendo un proceso iterativo:

- **Nodos Adyacentes como Nuevos Centros:** Cada nodo adyacente que se conecta al nodo central se convierte en un nuevo centro de expansión. Desde estos nodos, el algoritmo evalúa y establece conexiones adicionales con sus nodos vecinos.
- **Criterios de Conectividad:** La expansión sigue criterios específicos para maximizar la eficiencia del flujo de transporte y la conectividad de la red. Se busca optimizar las rutas basándose en la demanda real de transporte y la distancia, evitando rutas que no contribuyan significativamente a la red general.

- **Balance entre Expansión y Redundancia**

El Algoritmo de Fuente Única se centra en balancear la necesidad de expansión con la minimización de redundancias:

- **Minimización de Costos:** Se evita la duplicación de rutas mediante una evaluación constante de la eficiencia de cada nueva conexión. Solo se establecen rutas que contribuyan positivamente a la conectividad y eficiencia general de la red.
- **Mantenimiento de Conectividad:** Asegura que todos los nodos estén conectados de manera efectiva al nodo central o a la red establecida, evitando la creación de subgrafos desconectados.

- **Proceso de Implementación:**

- Preparación de Datos: El proceso de implementación del Algoritmo de Fuente Única comienza con la preparación de datos, similar al Algoritmo de Múltiples Fuentes. Esto incluye la limpieza y transformación de datos para representar adecuadamente las conexiones y nodos en la red de transporte
- Simulación de Expansión: La simulación se lleva a cabo mediante la programación del algoritmo para que expanda gradualmente la red desde el nodo central. Los pasos específicos incluyen:
 - Inicialización: Configuración del nodo central y la evaluación de las primeras conexiones.
 - Iteración: Expansión iterativa hacia nodos adyacentes, actualización de la red y evaluación de nuevas conexiones en cada iteración.

- **Análisis de Resultado:**

Los resultados de la simulación se analizan para evaluar la efectividad del Algoritmo de Fuente Única en comparación con el Algoritmo de Múltiples Fuentes. Las métricas clave incluyen la eficiencia del flujo de transporte, la conectividad de la red y los costos de construcción y mantenimiento.

- **Validación y Ajuste:**

La validación del algoritmo se realiza mediante la comparación de los resultados con redes de transporte reales y la evaluación de su rendimiento en diferentes escenarios. Se ajustan los parámetros del algoritmo según sea necesario para mejorar la eficiencia y la precisión de las simulaciones.

Resultados y Comparación

- **Eficiencia y Conectividad:**

El Algoritmo de Fuente Única generalmente muestra mejoras en la eficiencia del flujo de transporte y la conectividad de la red en comparación con el Algoritmo de Múltiples Fuentes. Al expandirse de manera más controlada desde un nodo central, se minimizan las redundancias y se optimiza la utilización de recursos.

- **Reducción de Costos:**

La reducción de costos es una ventaja significativa del Algoritmo de Fuente Única. Al evitar la duplicación de rutas y establecer conexiones más eficientes, el algoritmo reduce los costos asociados con la construcción y el mantenimiento de la infraestructura de transporte.

- **Mejora de la Escalabilidad:**

El enfoque de una sola fuente mejora la escalabilidad del algoritmo, haciéndolo más adecuado para su aplicación en redes grandes y complejas. La expansión controlada

facilita la gestión y la optimización de la red, permitiendo una mayor adaptabilidad a diferentes tamaños y configuraciones de redes de transporte.

Limitaciones y Consideraciones

- **Dependencia del Nodo Central:**

Una limitación del Algoritmo de Fuente Única es su dependencia del nodo central seleccionado. La elección de este nodo puede influir significativamente en los resultados, por lo que es crucial seleccionar un nodo que represente adecuadamente la demanda y la conectividad de la red.

- **Dependencia del Nodo Central:**

El algoritmo puede necesitar ajustes para adaptarse a cambios en la demanda de transporte o la distribución geográfica de la población. Es importante considerar cómo el algoritmo puede responder a dinámicas cambiantes en la red de transporte para mantener su efectividad a largo plazo.

El Algoritmo de Single Source ofrece una mejora significativa al Algoritmo de Múltiples Fuentes al proporcionar una expansión más controlada y eficiente de la red de transporte. Este enfoque permite optimizar la conectividad y la eficiencia del flujo de transporte, reducir los costos y mejorar la escalabilidad del algoritmo. La implementación de este enfoque en la planificación de redes de transporte en España puede contribuir a la creación de infraestructuras más eficientes y sostenibles, facilitando una mejor movilidad y conectividad en todo el país.

CONCLUSIONES

Este estudio ha evaluado la aplicación de un algoritmo inspirado en el moho mucilaginoso *Physarum polycephalum* para la optimización de la red de transporte ferroviario en España, comparándolo con la red ferroviaria actual. Los objetivos principales eran mejorar la eficiencia de la red, reducir los costos de mantenimiento y aumentar la conectividad tanto intrarregional como interregional. Los resultados obtenidos permiten extraer las siguientes conclusiones:

El algoritmo propuesto ha demostrado una notable capacidad para generar redes de transporte que, en ciertos casos, mejoran la estructura de la red ferroviaria actual. Ha replicado eficazmente la conectividad en regiones con alta densidad poblacional y proximidad geográfica, lo que ha permitido la formación de redes intrarregionales bien integradas y con alta redundancia. Este comportamiento se ha observado particularmente en la Región Norte (Cantabria, País Vasco, Navarra y La Rioja), donde el algoritmo ha aumentado las conexiones intrarregionales a 7 y las interregionales a 10, comparado con 5 y 6 respectivamente en la red actual.

Un hallazgo clave es la alta sensibilidad del algoritmo a los nodos con presiones poblacionales muy elevadas, lo que provoca una expansión radial desde estos nodos. En el caso de Madrid, esta centralidad ha resultado en una red donde la capital actúa como el nodo principal, con la capacidad de conectar prácticamente con todos los demás nodos del grafo. Este fenómeno ha generado una gran cantidad de conexiones interregionales (22), aunque ha concentrado la dependencia de la red en un solo punto, lo que puede limitar la resiliencia de la red en caso de fallos o congestiones en Madrid.

El algoritmo ha mostrado un desempeño superior en ciertas regiones comparadas con la red actual. Por ejemplo:

- En la Región Norte (Cantabria, País Vasco, Navarra y La Rioja), el algoritmo ha mejorado tanto la conectividad intrarregional como la interregional, sugiriendo una red más robusta y flexible.
- En la Región Este (Comunidad Valenciana y Murcia), el número de conexiones intrarregionales ha aumentado a 4 en comparación con 3 en la red actual, lo que mejora la cohesión interna. Las conexiones interregionales también han sido mejoradas, de 7 a 5, facilitando una integración eficiente con otras regiones.

Sin embargo, el algoritmo ha enfrentado desafíos en regiones con baja densidad poblacional y mayor dispersión geográfica:

- Región Noroeste (Galicia y Asturias): La región ha quedado desconectada en la red generada por el algoritmo, lo que destaca su ineficacia para zonas con baja densidad de población y distancias significativas entre nodos. Esta desconexión indica que el modelo actual ofrece una mejor solución para esta región.
- Región Oeste (Extremadura): A pesar de mantener las conexiones interregionales (3), la red generada solo ha mantenido una conexión intrarregional, lo que sugiere que el algoritmo no ha logrado mejorar la cohesión interna comparado con la red actual.

La distancia total acumulada por los caminos en la red generada por el algoritmo es de 13.545,9 km, lo que representa una mayor extensión comparada con los 11.872,8 km de la red actual. Esta expansión en la distancia se debe a la mayor cantidad de conexiones interregionales, especialmente desde nodos con alta presión poblacional como Madrid. Aunque esto puede mejorar la conectividad, también podría incrementar los costos de mantenimiento y operación, un aspecto que requiere consideración para una implementación práctica.

El estudio revela que el algoritmo de *Physarum polycephalum* es efectivo para mejorar la conectividad en regiones con alta densidad poblacional y proximidad geográfica. Su capacidad para expandirse radialmente desde nodos con alta presión poblacional como Madrid muestra una ventaja en maximizar la conectividad interregional. No obstante, su efectividad se reduce en áreas con baja densidad de población y alta dispersión geográfica, donde la red actual muestra una mejor adaptación.

BIBLIOGRAFÍA Y REFERENCIAS

- [1] Fernandez, S. S., & JUSMET, J. R. (2010). Agotamiento de los combustibles fósiles y emisiones de CO₂: algunos posibles escenarios futuros de emisiones. *Revista Galega de Economía*, 19(1), 1-19.
- [2] CLEVELAND, C.; HALL, C.; HALLOCK, H.; JEFFERSON, M.; THARAKAN, P. (2003): "Hydrocarbons and the Evolution of Human Culture", *Nature*, vol. 426, pp. 318-322.
- [3] Sprei, F., Karlsson, S., & Holmberg, J. (2008). Better performance or lower fuel consumption: Technological development in the Swedish new car fleet 1975–2002. *Transportation Research Part D: Transport and Environment*, 13(2), 75-85.
- [6] Dell'Olio, L., Gonzalo Orden, H., & Rojo Arce, M. (2006). Hacia un diseño eficiente de sistemas de transporte público en áreas urbanas.
- [7] Fu, L., Sun, D., & Rilett, L. R. (2006). Heuristic shortest path algorithms for transportation applications: State of the art. *Computers & Operations Research*, 33(11), 3324-3343.
- [8] Sim, K. M., & Sun, W. H. (2002, November). Multiple ant-colony optimization for network routing. In *First International Symposium on Cyber Worlds, 2002. Proceedings.* (pp. 277-281). IEEE.
- [9] Marinakis, Y., Marinaki, M., & Dounias, G. (2010). A hybrid particle swarm optimization algorithm for the vehicle routing problem. *Engineering Applications of Artificial Intelligence*, 23(4), 463-472.
- [10] Tero, A., Takagi, S., Saigusa, T., Ito, K., Bebber, D.P., Fricker, M.D., Yumiki, K., Kobayashi, R. & Nakagi, T. (2010). Rules for Biologically Inspired Adaptive Network Design. *Science*, 327 (5964), 439-442.
- [11] Tero, A., Kobayashi, R., & Nakagaki, T. (2007). A mathematical model for adaptive transport network in path finding by true slime mold. *Journal of theoretical biology*, 244(4), 553-564.
- [12] Zhang, X., Adamatzky, A., Chan, F. T., Deng, Y., Yang, H., Yang, X. S., ... & Mahadevan, S. (2015). A biologically inspired network design model. *Scientific reports*, 5(1), 10794.
- [13] Zhang, X., Wang, Q., Adamatzky, A., Chan, F. T., Mahadevan, S., & Deng, Y. (2014). An improved physarum polycephalum algorithm for the shortest path problem. *The Scientific World Journal*, 2014.
- [14] Zhang, X., Zhang, Y., Zhang, Z., Mahadevan, S., Adamatzky, A., & Deng, Y. (2014). Rapid Physarum Algorithm for shortest path problem. *Applied Soft Computing*, 23, 19-26.
- [15] X. Zhang, Y. Zhang, Y. Hu, Y. Deng, and S. Mahadevan, "An adaptive amoeba algorithm for constrained shortest paths," *Expert Systems With Applications*, vol. 40, no. 18, pp. 7607–7616, 2013
- [16] Chen, L., & Yang, H. Managing congestion and emissions in road networks with tolls and rebates. *Transp. Res. Part B: Methodological* 46, 933–948 (2012).
- [17] Baublys, A., & Išoraitė, M. Improvement of external transport cost evaluation in the context of Lithuanias integration into the European Union. *Transport Reviews* 25, 245–259 (2005).
- [18] Bain, N., & Bartolo, D. (2019). Dynamic response and hydrodynamics of polarized crowds. *Science*, 363(6422), 46-49.
- [23] Bonifaci, V., Mehlhorn, K., Varma, G. (2012). Physarum can compute shortest pats. In Rabani Y. (Ed.) *Proc. of the 23rd ACM-SIAM Symposium on Discrete Algorithms*, SIAM, 233-240.

[24] Bonifaci, V., Mehlhorn, K., Varma, G. (2012). Physarum can compute shortest paths. Journal of Theoretical Biology, 309. 121-133.

Portales de internet:

[4] Ranking internacional de trenes de Alta Velocidad. (s. f.-c). <https://www.revistatren.com/noticias/177ranking-internacional-de-trenes-de-alta-velocidad>

[5] Roperio, M. (2023, 5 junio). El tren se convierte en el medio de transporte menos contaminante. Antena 3 Noticias. https://www.antena3.com/noticias/el-tiempo/actualidad/tren-convierte-medio-transportemenos-contaminante_20230605647dc586a7fe8d0001d44120.html

[19] Nacional, I. G. (s. f.). Instituto Geográfico Nacional. Geoportal Oficial del Instituto Geográfico Nacional de España. <https://www.ign.es/web/ane-datos-geograficos/-/datosgeograficos/datosPoblacion?tipoBusqueda=capitales>

[20] Download RStudio | The Popular Open-Source IDE from Posit. (2023b, julio 26). Posit. <https://posit.co/products/open-source/rstudio/>

[21] Luca. (s. f.). ¿Qué es Python? ¿Qué Es Python? <https://web.archive.org/web/20200224120525/https://luca-d3.com/es/data-speaks/diccionariotecnologico/python-lenguaje>

[22] NetworkX — NetworkX documentation. (s. f.). <https://networkx.org/>

ANEXO

A continuacion se incluye el código utilizado para creación y ejecución del algoritmo:

```
import random
import pandas
as pd
import time
import
math
import networkx as nx
import matplotlib.pyplot as plt

# Cargamos los datos

Ciudades_excel = "C:/Users/Tomas/Desktop/Uni/TFG/DataSet/CapitalesProvincia/Capitales.xlsx"

hoja_excel_ciudades = "Nodos"

Presiones_excel = "C:/Users/Tomas/Desktop/Uni/TFG/DataSet/CapitalesProvincia/Presiones.xlsx"

hoja_excel_presiones = "Nodos"

df1 = pd.read_excel(Ciudades_excel, sheet_name=hoja_excel_ciudades)

ciudad = df1["Capital"]
coordenadas_x = df1["X"]
coordenadas_y = df1["Y"]

df2 = pd.read_excel(Presiones_excel, sheet_name=hoja_excel_presiones)

presion = df2["Presion"]

# Lista de tuples coordenadas = list(zip(ciudad, coordenadas_x,
coordenadas_y))
presiones = list(zip(ciudad, presion))

# Clase Nodo para representar los nodos en el grafo

class Nodo:
    def __init__(self, nombre,
coordenadas, presion):

        self.nombre = nombre
        self.presion = presion
        self.coordenadas = coordenadas

self.permanencia = presion # Indica cuánta gente su destino es dicho nodo. Es igual a la presión

self.conexiones = 0

# Clase Camino para representar las conexiones entre nodos

class Camino:
    def __init__(self, nodo_inicio, nodo_fin):

        self.nodo_inicio = nodo_inicio
        self.nodo_fin = nodo_fin
        self.anchos =
random.uniform(0.5, 1)
        self.presion = nodo_inicio.presion * self.anchos +
nodo_fin.presion * self.anchos
        self.longitud =
self.calcular_distancia(nodo_inicio.coordenadas, nodo_fin.coordenadas)
        self.flujo =
(self.anchos * self.presion) / self.longitud if self.longitud != 0 else 0
        self.energia =
self.flujo
        self.gasto = ((self.anchos) * (self.longitud)) * Omega

def calcular_distancia(self, coord1, coord2):
```



```

return math.sqrt(sum((x - y) ** 2 for x, y in zip(coord1, coord2)))

# Función para eliminar una conexión entre dos nodos
def eliminar_conexion(nodo_inicio, nodo_fin):
    nodo_inicio.conexiones -= 1
    nodo_fin.conexiones -= 1

# Función para calcular el ancho de un camino def
def calcular_ancho_camino(camino):
    camino.ancho = camino.energia - camino.gasto
    if camino.ancho > 1:
        camino.ancho = 1
    camino.energia = camino.flujo
    camino.gasto = (camino.ancho) * (camino.longitud) * Omega
    camino.flujo = (camino.ancho * camino.presion) / camino.longitud
    if camino.ancho < 0.01:
        if camino.nodo_inicio.conexiones == 1 or camino.nodo_fin.conexiones == 1:
            camino.ancho = 0.01
        else:
            eliminar_conexion(camino.nodo_inicio, camino.nodo_fin)
    return -1
return camino.ancho

# Función para crear un grafo completo a partir de las coordenadas y presiones def
def crear_grafo_completo(coordenadas, presiones):
    nodos = [Nodo(str(coordenadas[i][0]), (coordenadas[i][1], coordenadas[i][2]), presiones[i][1]) for i, _ in enumerate(coordenadas)]
    caminos = []
    for i in range(len(coordenadas)):
        for j in range(i + 1, len(coordenadas)):
            camino = Camino(nodos[i], nodos[j])
            caminos.append((nodos[i], nodos[j], camino))
            nodos[i].conexiones += 1
            nodos[j].conexiones += 1
    return nodos, caminos

# Función para actualizar las presiones de los nodos
def actualizar_presiones(caminos):
    for nodo_inicio, nodo_fin, _ in caminos:
        nodo_fin.presion /= nodo_fin.conexiones
        nodo_inicio.presion /= nodo_inicio.conexiones

# Función para dibujar el grafo def
def dibujar_grafo(nodos, caminos):
    G = nx.Graph()
    for nodo in nodos:
        G.add_node(nodo.nombre, presion=nodo.presion, coordenadas=nodo.coordenadas)
    for nodo_inicio, nodo_fin, camino in caminos:
        G.add_edge(nodo_inicio.nombre, nodo_fin.nombre, ancho=camino.ancho, longitud=camino.longitud, flujo=camino.flujo)
    posiciones = {nodo.nombre: nodo.coordenadas for nodo in nodos}
    etiquetas = {nodo.nombre: nodo.nombre for nodo in nodos}
    flujo_caminos = [camino[2].ancho for camino in caminos]
    plt.figure(figsize=(15, 15))
    nx.draw(G, posiciones,

```

```

with_labels=True, labels=etiquetas, node_size=100, node_color='skyblue', font_size=7, font_color='black',
width=flujo_caminos, edge_color='grey', edge_cmap=plt.cm.Blues, edge_vmin=min(flujo_caminos),
edge_vmax=max(flujo_caminos)) plt.show()

```

```

# MAIN def main(iteraciones, Omega, coordenadas, presiones):
nodos, caminos = crear_grafo_completo(coordenadas, presiones)
n_iteraciones_sin Eliminacion = 0

```

```

while n_iteraciones_sin Eliminacion < iteraciones:
    caminos_Eliminados = False
    for camino

```

```

in caminos.copy():
        if
calcular_ancho_camino(camino[2]) == -1:
            caminos.remove(camino)

```

```

caminos_Eliminados = True
        if not
caminos_Eliminados:

```

```

            n_iteraciones_sin Eliminacion += 1
        else:
            n_iteraciones_sin Eliminacion = 0
actualizar_presiones(caminos)

```

```

# Filtrar caminos con ancho = 1
    caminos_ancho_1 = [camino for camino
in caminos if camino[2].ancho == 1]
    return nodos, caminos_ancho_1

```

```

# Ejecución iteraciones =
5
Omega = 0.85
inicio_tiempo = time.time()

```

```

nodos_restantes, caminos_ancho_1 = main(iteraciones, Omega, coordenadas, presiones)

```

```

fin_tiempo = time.time()

```

```

# Dibujar el gráfico final
dibujar_grafo(nodos_restantes,
caminos_ancho_1)

```

```

# Crear listas de los nodos y caminos con ancho = 1
nodos_finales
= [{
    "Nombre": nodo.nombre,
    "Presion": nodo.presion,
    "Coordenadas": nodo.coordenadas,

```

```
"Conexiones": nodo.conexiones
} for nodo in nodos_restantes]
```

```
caminos_finales = [{
    "Nodo Inicio": camino[0].nombre,
    "Nodo Fin": camino[1].nombre,
} for camino in caminos_ancha_1]
```

```
print("\nCaminos:") for camino in caminos_ancha_1: print(f"Nodo Inicio: {camino[0].nombre}, Nodo Fin: {camino[1].nombre}, Ancho: {camino[2].ancho},
Longitud: {camino[2].longitud}, Flujo: {camino[2].flujo}")
```

```
tiempo_ejecucion = fin_tiempo - inicio_tiempo print(f"Tiempo
de ejecución: {tiempo_ejecucion} segundos")
```

```
distancia = 111 * sum(camino[2].longitud for camino in caminos_ancha_1) print(f"Distancia
Total: {distancia} km")
```