



VNiVERSiDAD DE SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

UNIVERSIDAD DE SALAMANCA

Departamento de Informática y Automática

Facultad de Ciencias

TESIS DOCTORAL

Tecnologías vestibles para la seguridad en el trabajo: Un modelo basado en los equipos de protección individual inteligentes

Autor:

D. Sergio Márquez Sánchez

Directores:

Dr. D. Juan Manuel Corchado Rodríguez

Dra. Dña. Sara Rodríguez González

Abril de 2022



VNiVERSiDAD
DE SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

UNIVERSITY OF SALAMANCA

Department of Computer Science and Automation

Faculty of Sciences

DOCTORAL THESIS

Wearable technologies for safety at work: A framework based on Smart Personal Protective Equipment

Author:

D. Sergio Márquez Sánchez

Advisors:

Dr. D. Juan Manuel Corchado Rodríguez

Dra. Dña. Sara Rodríguez Gonzalez

April, 2022



VNiVERSiDAD DE SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

UNIVERSIDAD DE SALAMANCA

Departamento de Informática y Automática

Facultad de Ciencias

Tecnologías vestibles para la seguridad en el trabajo: Un modelo basado en los equipos de protección individual inteligentes

Autor:

D. Sergio Márquez Sánchez

Directores:

Dr. D. Juan Manuel Corchado Rodríguez

Dra. Dña. Sara Rodríguez González

TRIBUNAL

Presidente:

Vocal:

Secretario:

Suplentes:

FECHA DE LECTURA:

CALIFICACIÓN:

A mi padre

A mi madre

A mi hermana

A mi abuelo

A mi familia

A mis amigos

Solicitud de Presentación de Tesis Doctoral

Estimado Coordinador del Programa de Doctorado en Inginería Informática:

D. Sergio Márquez Sánchez, con DNI 70891085-W, y alumno del programa de DOCTORADO EN INGENIERÍA INFORMÁTICA, matriculado en el plan de estudios D015 INGENIERÍA INFORMÁTICA (R.D. 99/2011) y con número de expediente 85:

Solicita que se tenga en consideración la información aportada en este documento con el objeto de poder presentar la Tesis Doctoral con título *Tecnologías vestibles para la seguridad en el trabajo: Un modelo basado en los equipos de protección individual inteligentes* mediante el formato de compendio de artículos/publicaciones. La información aportada se corresponde con lo establecido en el Procedimiento para la presentación de la Tesis Doctoral en la Universidad de Salamanca en el Formato de Compendio de Artículos/Publicaciones.

A continuación se detallan los documentos adjuntos en esta solicitud:

- Página Inicial especificando que la Tesis Doctoral corresponde a un compendio de trabajos previamente publicados, detallando para cada uno de ellos: referencia de la revista, editorial, DOI y afiliaciones de cada uno de los miembros autores.
- Autorización de los directores para la presentación de la Tesis Doctoral mediante el formato de compendio de artículos/publicaciones.
- Introducción y resumen de la Tesis Doctoral presentada.
 - Introducción.
 - Metodología de investigación.
 - Objetivos de la Tesis Doctoral.
 - Estado del arte.
 - Contribuciones.
 - Publicaciones.
 - Proyectos.
 - Conclusiones.
 - Trabajo futuro.

- Copia completa de las publicaciones originales que conformarán la Tesis Doctoral (artículos, capítulos de libro, libro o libros aceptados o publicados), incluyendo un resumen de la publicación, una introducción con los antecedentes del tema objeto de estudio, la hipótesis de trabajo y los objetivos de la investigación, así como los principales resultados y conclusiones finales de cada uno de ellos.

En Salamanca, a 22 de abril de 2022

El doctorando

D. Sergio Márquez Sánchez

Autorización de los directores

En Salamanca, a 13 de abril de 2022,

HACEMOS CONSTAR:

Que, como directores de la Tesis Doctoral de Sergio Márquez Sánchez, con DNI 70891085W, autorizados a presentar la Tesis Doctoral “Tecnologías vestibles para la seguridad en el trabajo con equipos inteligente de protección individual” mediante la modalidad de compendio de artículos, al disponer de los siguientes artículos publicados:

1. Campero-Jurado, I., Márquez-Sánchez, S., Quintanar-Gómez, J., Rodríguez, S., & Corchado, J. M. (2020). Smart Helmet 5.0 for industrial internet of things using artificial intelligence. *Sensors*, 20(21), 6241.
2. Márquez-Sánchez, S., Campero-Jurado, I., Herrera-Santos, J., Rodríguez, S., & Corchado, J. M. (2021). Intelligent Platform Based on Smart PPE for Safety in Workplaces. *Sensors*, 21(14), 4652.
3. Márquez-Sánchez, S., Campero-Jurado, I., Robles-Camarillo, D., Rodríguez, S., & Corchado-Rodríguez, J. M. (2021). BeSafe B2. 0 Smart Multisensory Platform for Safety in Workplaces. *Sensors*, 21(10), 3372.

Los directores:

Dr. Juan Manuel Corchado Rodríguez

Dra. Sara Rodríguez González



D. /Dª. Juan Manuel Corchado Rodríguez

HAGO CONSTAR:

Que soy COAUTOR/A de los siguientes trabajos:

Campero-Jurado, I., Márquez-Sánchez, S., Quintanar-Gómez, J., Rodríguez, S., & Corchado, J. M. (2020). Smart Helmet 5.0 for industrial internet of things using artificial intelligence. *Sensors*, 20(21), 6241.

Márquez-Sánchez, S., Campero-Jurado, I., Herrera-Santos, J., Rodríguez, S., & Corchado, J. M. (2021). Intelligent Platform Based on Smart PPE for Safety in Workplaces. *Sensors*, 21(14), 4652.

Márquez-Sánchez, S., Campero-Jurado, I., Robles-Camarillo, D., Rodríguez, S., & Corchado-Rodríguez, J. M. (2021). BeSafe B2. 0 Smart Multisensory Platform for Safety in Workplaces. *Sensors*, 21(10), 3372.

Y MANIFIESTO QUE:

Como COAUTOR/A NO DOCTOR/A del trabajo del doctorando _____
expreso mi RENUNCIA a presentar el artículo como parte de otra Tesis Doctoral.

Como COAUTOR/A del trabajo del doctorando Sergio Márquez Sánchez
acepto que dicho trabajo sea presentado como parte de su Tesis Doctoral y declaro que el doctorando es el autor principal
de la investigación recogida en estos trabajos.

Salamanca a 13 de septiembre de 2021

Firmado digitalmente por CORCHADO
RODRIGUEZ JUAN MANUEL - 70978310B
Fecha: 2021.09.13 18:09:09 +01'00'

Fdo: Juan Manuel Corchado Rodríguez

COMISIÓN ACADÉMICA DEL PROGRAMA DE DOCTORADO

D. /Dª. Sara González Rodríguez

HAGO CONSTAR:

Que soy COAUTOR/A de los siguientes trabajos:

Campero-Jurado, I., Márquez-Sánchez, S., Quintanar-Gómez, J., Rodríguez, S., & Corchado, J. M. (2020). Smart Helmet 5.0 for industrial internet of things using artificial intelligence. *Sensors*, 20(21), 6241.

Márquez-Sánchez, S., Campero-Jurado, I., Herrera-Santos, J., Rodríguez, S., & Corchado, J. M. (2021). Intelligent Platform Based on Smart PPE for Safety in Workplaces. *Sensors*, 21(14), 4652.

Márquez-Sánchez, S., Campero-Jurado, I., Robles-Camarillo, D., Rodríguez, S., & Corchado-Rodríguez, J. M. (2021). BeSafe B2. 0 Smart Multisensory Platform for Safety in Workplaces. *Sensors*, 21(10), 3372.

Y MANIFIESTO QUE:

Como COAUTOR/A NO DOCTOR/A del trabajo del doctorando _____
expreso mi RENUNCIA a presentar el artículo como parte de otra Tesis Doctoral.

Como COAUTOR/A del trabajo del doctorando Sergio Márquez Sánchez
acepto que dicho trabajo sea presentado como parte de su Tesis Doctoral y declaro que el doctorando es el autor principal
de la investigación recogida en estos trabajos.

Salamanca a 16 de septiembre de 2021

RODRIGUEZ
GONZALEZ SARA
- 70864126E

Firmado digitalmente por
RODRIGUEZ GONZALEZ
SARA - 70864126E
Fecha: 2021.09.16
10:42:12 +02'00'

Fdo: Sara Rodríguez González

COMISIÓN ACADÉMICA DEL PROGRAMA DE DOCTORADO

D. /D^a. Israel Campero Jurado

HAGO CONSTAR:

Que soy COAUTOR/A de los siguientes trabajos:

Campero-Jurado, I., Márquez-Sánchez, S., Quintanar-Gómez, J., Rodríguez, S., & Corchado, J. M. (2020). Smart Helmet 5.0 for industrial internet of things using artificial intelligence. *Sensors*, 20(21), 6241.

Márquez-Sánchez, S., Campero-Jurado, I., Herrera-Santos, J., Rodríguez, S., & Corchado, J. M. (2021). Intelligent Platform Based on Smart PPE for Safety in Workplaces. *Sensors*, 21(14), 4652.

Márquez-Sánchez, S., Campero-Jurado, I., Robles-Camarillo, D., Rodríguez, S., & Corchado-Rodríguez, J. M. (2021). BeSafe B2. 0 Smart Multisensory Platform for Safety in Workplaces. *Sensors*, 21(10), 3372.

Y MANIFIESTO QUE:

Como COAUTOR/A NO DOCTOR/A del trabajo del doctorando Sergio Márquez Sánchez
expreso mi RENUNCIA a presentar el artículo como parte de otra Tesis Doctoral.

Como COAUTOR/A del trabajo del doctorando Sergio Márquez Sánchez
acepto que dicho trabajo sea presentado como parte de su Tesis Doctoral y declaro que el doctorando es el autor principal
de la investigación recogida en estos trabajos.

Salamanca a 22 de abril de 2022



Fdo: Israel Campero Jurado

COMISIÓN ACADÉMICA DEL PROGRAMA DE DOCTORADO

D. /D^a. Jorge Herrera Santos

HAGO CONSTAR:

Que soy COAUTOR/A de los siguientes trabajos:

Márquez-Sánchez, S., Campero-Jurado, I., Herrera-Santos, J., Rodríguez, S., & Corchado, J. M. (2021). Intelligent Platform Based on Smart PPE for Safety in Workplaces. *Sensors*, 21(14), 4652.

Y MANIFIESTO QUE:

- Como COAUTOR/A NO DOCTOR/A del trabajo del doctorando Sergio Márquez Sánchez
expreso mi RENUNCIA a presentar el artículo como parte de otra Tesis Doctoral.
- Como COAUTOR/A del trabajo del doctorando Sergio Márquez Sánchez
acepto que dicho trabajo sea presentado como parte de su Tesis Doctoral y declaro que el doctorando es el autor principal
de la investigación recogida en estos trabajos.

Salamanca a 22 de abril de 2022

HERRERA SANTOS
JORGE -
70938872H

Firmado digitalmente por
HERRERA SANTOS JORGE -
70938872H
Fecha: 2022.04.21 20:09:02
+02'00'

Fdo: Jorge Herrera Santos

COMISIÓN ACADÉMICA DEL PROGRAMA DE DOCTORADO

D. /D^a. Juan Quintanar Gómez

HAGO CONSTAR:

Que soy COAUTOR/A de los siguientes trabajos:

Campero-Jurado, I., Márquez-Sánchez, S., Quintanar-Gómez, J., Rodríguez, S., & Corchado, J. M. (2020). Smart Helmet 5.0 for industrial internet of things using artificial intelligence. Sensors, 20(21), 6241

Y MANIFIESTO QUE:

- Como COAUTOR/A NO DOCTOR/A del trabajo del doctorando Sergio Márquez Sánchez
expreso mi RENUNCIA a presentar el artículo como parte de otra Tesis Doctoral.
- Como COAUTOR/A del trabajo del doctorando Sergio Márquez Sánchez
acepto que dicho trabajo sea presentado como parte de su Tesis Doctoral y declaro que el doctorando es el autor principal de la investigación recogida en estos trabajos.

Salamanca a 22 de abril de 2022

Fdo: 
Juan Quintanar Gómez

D. /D^a. Daniel Robles Camarillo

HAGO CONSTAR:

Que soy COAUTOR/A de los siguientes trabajos:

Márquez-Sánchez, S., Campero-Jurado, I., Robles-Camarillo, D., Rodríguez, S., & Corchado-Rodríguez, J. M. (2021). BeSafe B2. 0 Smart Multisensory Platform for Safety in Workplaces. *Sensors*, 21(10), 3372.

Y MANIFIESTO QUE:

- Como COAUTOR/A NO DOCTOR/A del trabajo del doctorando _____
expreso mi RENUNCIA a presentar el artículo como parte de otra Tesis Doctoral.
- Como COAUTOR/A del trabajo del doctorando Sergio Márquez Sánchez
acepto que dicho trabajo sea presentado como parte de su Tesis Doctoral y declaro que el doctorando es el autor principal
de la investigación recogida en estos trabajos.

Salamanca a 13 de septiembre de 2021

Fdo: Daniel Robles Camarillo


COMISIÓN ACADÉMICA DEL PROGRAMA DE DOCTORADO

“Lo único que está entre tu meta y tú, es la historia que te sigues contando a ti mismo de por qué no puedes lograrla. Manten tu mirada en las estrellas, y tus pies en la tierra.”

Theodore Roosevelt

Resumen

La inteligencia artificial de las cosas, o AIoT por sus siglas en inglés Artificial Intelligence of Things, se presenta como la unión de tecnologías de inteligencia artificial con la infraestructura de Internet de las cosas para conseguir dispositivos Internet of Things (IoT) más eficientes. La combinación de AIoT con el uso de la tecnología vestible o wearable se presenta como un conjunto de técnicas clave en la implantación de soluciones de monitorización y prevención dentro del sector industrial, motor principal del desarrollo económico y social de la sociedad. Además, con la integración de la tecnología Edge Computing en las plataformas se consigue preprocesar los datos y filtrar aquellos que se necesiten enviar desde la capa IoT a la nube, solucionando problemas relativos a la privacidad y seguridad de los datos, así como la reducción de costes en servicios Cloud. Es necesario que los trabajadores del sector conozcan y cumplan las normas de seguridad de la industria, destinadas a garantizar su seguridad en el trabajo, pero además, se requiere una transformación en los Equipos de Protección Individual (EPIs) y sistemas auxiliares de detección, aviso e identificación de riesgos; dotándoles de inteligencia para la toma de decisiones. La solución propuesta tiene un enfoque holístico motivado en generar una plataforma que componga un entorno mucho más favorable para la protección personal de los trabajadores. Para ello, se han analizado las diferentes soluciones y equipos que puedan integrarse en un modelo que optimice la detección y prevención de riesgos, así como la detección de las condiciones de salud inherentes a tareas específicas en el lugar de trabajo. La plataforma incorpora la capacidad de recepción de datos y generación de alarmas, combinando el uso de dispositivos electrónicos wearables e IoT, Inteligencia Artificial y Edge Computing. Gracias a la agregación e integración de las tecnologías citadas se permite generar soluciones que mejoren la seguridad y productividad, se consigue disminuir las bajas laborales y a su vez tener un mayor control de la industria y sus operarios. Con ello se dota a la plataforma de mayores capacidades que las soluciones desarrolladas hasta la fecha, generando una plataforma modular que agrupa nuevos dispositivos wearables combinados con tecnologías permiten realizar una medición de parámetros corporales, reconocimiento de la actividad humana, detección de contaminantes y la detección de situaciones anómalas para generar entornos de trabajo más seguros.

Abstract

The industrial sector is key to economic and social development; however, it is also known to entail certain risks for workers. To ensure their security, workers in the sector must be informed of and comply with industrial safety standards. Moreover, industries are required to transform their Personal Protective Equipment (PPE) and auxiliary systems by providing them with intelligence for timely risk identification, warnings, and decision-making. Artificial Intelligence of Things, or AIoT for short, combines Artificial Intelligence technologies with Internet of Things infrastructure to achieve more efficient Internet of Things (IoT) devices, creating great potential for industrial use. In addition, platforms that integrate Edge Computing technology have the ability to preprocess data and filter those that need to be sent from the IoT layer to the Cloud. This not only solves problems related to data privacy and security but also reduces Cloud service costs. Thus, in this thesis, the joint use of AIoT and wearable technology is proposed through a set of key techniques, devices and a platform for worker monitoring and risk prevention in an industrial setting. The proposed solution has a holistic approach aimed at creating a much more favorable environment for the personal protection of workers. Prior to developing the proposed platform, an analysis has been carried out of the state-of-the-art solutions and equipment found in the literature, specifically, of the solutions that could be integrated in a system for the optimized prevention of risks and detection of health conditions. The developed platform has a modular design, combining the use of wearable technology, IoT electronic devices, Artificial Intelligence and Edge Computing. The results obtained in this thesis evidence that the proposed platform's capabilities surpass other solutions developed to date; the platform has the ability to receive data, emit alarms, measure body parameters, recognize human activity, detect pollutants and anomalous situations, creating safer working conditions.

Agradecimientos

A mis directores, Juan Manuel y Sara, por contar conmigo para formar parte de su equipo, permitirme avanzar en el mundo de la investigación y, por supuesto, dirigirme y ayudarme a culminar la realización de esta Tesis Doctoral con éxito.

A mis compañeros de investigación y colaboradores en las publicaciones durante la misma, especialmente a Jorge e Israel. Esta Tesis Doctoral refleja también vuestro trabajo. Sin vosotros esta Tesis no sería posible, profesionalmente sois excelentes pero como personas sois enormes, dos amigos que siempre ocuparán un lugar especial en mi vida.

A los mejores amigos que podría haber encontrado durante esta etapa, Ludeiro, Marta, Eugenia y Coral. Durante toda este camino vosotros habéis sido los que mejor me habéis entendido, gracias por tan buenos y bonitos momentos.

A todos mis compañeros del grupo BISITE a lo largo de este tiempo. Es un placer trabajar con todos vosotros y formar parte de este equipo. Gracias por hacer posible esta investigación.

Especial mención a Javier Ramón y Juan Manuel García, porque fueron los que me motivaron a hacer el doctorado y han seguido mis avances de forma muy directa.

A mis padres, porque me lo han dado todo en esta vida y me han ayudado en todo momento, apoyándome de todas las formas posibles.

A mi hermana, por hacerme sentir el hermano más orgulloso del mundo, todo un ejemplo de persona, que ilumina con su gran corazón mi vida.

A mi abuelo, un persona tan especial que sobran las palabras.

Y, por supuesto, a mis amigos y resto de mi familia, que siempre me han animado para que fuera completando los diferentes pasos para alcanzar esta meta.

¡Gracias a todos!

Índice general

1. Introducción	1
1.1. Descripción del problema	4
1.2. Hipótesis y objetivos	9
1.3. Metodología de investigación	11
1.4. Estructura de la Tesis Doctoral	14
1. Introduction	17
1.1. Problem description	20
1.2. Hypothesis and objectives	24
1.3. Research methodology	26
1.4. Doctoral Thesis structure	29
2. Estado del Arte	33
2.1. Introducción	36
2.2. Seguridad en el trabajo	43
2.3. IoT aplicado a EPIs, Wearables y Textiles inteligentes	46
2.4. Integración de Inteligencia Artificial	56
2.5. Plataformas y arquitecturas para la prevención	61
2.6. Conclusiones	64
3. Contribuciones	67
3.1. Introducción	69
3.2. Estructura plataforma	71
3.3. Descripción técnica	73
3.3.1. IoT Layer	73
3.3.2. Edge Layer	79
3.3.3. Server Layer	86
3.4. Casos de estudio	91
3.4.1. Casco inteligente	92
3.4.2. Brazalete inteligente	100
3.4.3. Cinturón inteligente	104
3.4.4. Plataforma de soporte integral con procesamiento Edge e integración de los diferentes dispositivos	107
3.5. Conclusiones	112
4. Publicaciones acreditativas de la investigación realizada	115
4.1. Smart Helmet 5.0 for industrial internet of things using artificial intelligence	119
4.1.1. Información de la publicación	119

4.1.2. Introducción	119
4.1.3. Objetivos	120
4.1.4. Conclusiones	121
4.1.5. Publicación original	121
Publicación original	122
4.2. BeSafe B2. 0 Smart Multisensory Platform for Safety in Workplaces	149
4.2.1. Información de la publicación	149
4.2.2. Introducción	149
4.2.3. Objetivos	151
4.2.4. Conclusiones	152
4.2.5. Publicación original	153
Publicación original	154
4.3. Intelligent Platform Based on Smart PPE for Safety in Workplaces	187
4.3.1. Información de la publicación	187
4.3.2. Introducción	187
4.3.3. Objetivos	189
4.3.4. Conclusiones	189
4.3.5. Publicación original	190
Publicación original	191
5. Evidencias y Resultados	213
5.1. Publicaciones	215
5.1.1. Publicaciones en revistas científicas internacionales	216
5.1.2. Publicaciones en congresos internacionales y workshops	217
5.2. Proyectos	218
5.3. Estancias internacionales	221
6. Conclusiones y Trabajo Futuro	223
6.1. Conclusiones	225
6.2. Líneas Futuras de Investigación	230
6. Conclusions and Future Work	233
6.1. Conclusions	235
6.2. Future Lines of Research	239
Bibliografía	241

Índice de figuras

1.1. Estadístico de accidentes de trabajo con respecto al período Enero-Diciembre 2021. (de Trabajo y Economía Social, 2021)	5
1.2. Estadístico de accidentes de trabajo con respecto al período Enero-Diciembre 2021 (de Trabajo y Economía Social, 2021)	7
1.1. Occupational accident statistics for the period January-December 2021. Ministry of Labor and Social Economy (de Trabajo y Economía Social, 2021)	21
1.2. Occupational accident statistics for the period January-December 2021 (de Trabajo y Economía Social, 2021)	23
3.1. Arquitectura de la plataforma Edge-AIoT.	72
3.2. Dispositivos EPIS Inteligentes integrados en la plataforma.	74
3.3. Casco con la electrónica integrada.	75
3.4. Diagrama de funcionamiento del firmware del casco.	76
3.5. Brazalete con la electrónica integrada.	77
3.6. Diagrama de funcionamiento del firmware del brazalete.	77
3.7. Diagrama de funcionamiento del firmware del brazalete.	78
3.8. Diagrama de funcionamiento del firmware del brazalete.	79
3.9. Diseño electrónico y disposición de los conectores y puertos.	84
3.10. Placa fabricada con los módulos y electrónica Surface Mount Technology (SMD).	86
3.11. Panel de selección de dispositivo.	88
3.12. Panel de visualización de datos casco.	88
3.13. Panel de visualización de datos brazalete.	89
3.14. Panel de visualización de datos cinturón.	89
3.15. Estructura de un proceso Machine Learning.	90
3.16. Fotografía de un operario con los dispositivos colocados.	91
3.17. Red neuronal convolucional profunda operación.	95
3.18. Resultados de la validación cruzada con el 20 % para el SVM.	96
3.19. Resultados de la validación cruzada con el 20 % para el NB.	96
3.20. Resultados de la validación cruzada con el 20 % para el NN.	97
3.21. Resultados de la validación cruzada con el 20 % para el CNN.	97
3.22. Resultados de la validación cruzada con el 20 % para el CNN.	98
3.23. Casco en la evaluación en un centro de transformación con alarma de gases activada.	99
3.24. Casco en la evaluación en un centro de transformación con alarma leve de gases activada.	99
3.25. Panel de visualización del casco.	100

3.26. Análisis de datos mediante la unión de un modelo basado en anomalías y otro basado en series temporales.	101
3.27. Resultados del GMM en tiempo real.	102
3.28. Matriz de confusión LSTM.	103
3.29. Imagen de los datos mostrados en la pantalla y de la alarma de pulso activa.	103
3.30. Panel de visualización del brazalete.	104
3.31. Curvas ROC para cada una de las clases representadas en la variable dependiente.	106
3.32. Operario configurando el cinturón en un centro de transformación.	107
3.33. Panel de visualización del cinturón.	107
3.34. Explicación del proceso de inclusión del ML para la toma de decisiones conjuntas en toda una red. El flujo del diagrama es de derecha a izquierda.	109
3.35. Interpretación final de los dispositivos mediante heurística y aprendizaje automático aplicado a redes complejas.	110
3.36. Imagen obtenida al trazar la red en el software Gephi.	111
3.37. Curvas de características operativas del receptor (ROC) en el análisis de diferentes modelos para la integración de la multiplataforma completa.	112

Siglas y acrónimos

AI	Artificial Intelligence
AIoT	Artificial Intelligence and Internet of Things
AmI	Ambiental Intelligence
ANN	Artificial Neural Network
ARCTM	Accident Root Causes Tracing Model
AR	Augmented Reality
ASEPAL	Asociación de Empresas de Equipos de Protección Individual
AQI	Air Quality Index
BCE	Banco Central Europeo
BCI	Brain -Computer Interfaces
CBR	Case-Based Reasoning
CBSN	Collaborative Body Sensor Networks
CM	Condition Monitoring
CMMS	Computerised Maintenance Management System
CNN/ConvNet	Convolutional Neural Network
CRT	Cathode Ray Tube
CUSUM	Cumulative Sum Control Chart
DBN	Deep Belief Networks
DHE	Danger due to Hostile Environment
DL	Deep Learning
DRL	Deep Reinforcement Learning
ECG	Electrocardiogram
EEG	Electroencephalographic
EM	Expectation-Maximization
EPI	Equipo de Protección Individual

EPC	Equipo de Protección Común
EPPI	Equipos Predictivos de Protección Industrial
ERP	Enterprise Resource Planning
FSR	Force Sensitive Resistor
GMM	Gaussian Mixture Model
GPS	Global Positioning System
HAR	Human Activity Recognition
HCUP	Healthcare Cost and Utilization Project
HID	Human Interface Device
HMM	Hidden Markov Modeling
HTTP	Hyper-Text Transfer Protocol
HUD	Head-Up Display
HW	Hardware
ICTs	Information and Communication Technologies
IMU	Inertial Measurement Unit
IoT	Internet of Things
IIoT	Industrial Internet of Things
IITEM	Intelligent Internet of Things for Equipment Maintenance
IoRT	Internet of Robotic Things
JSON	JavaScript Object Notation
KBS	Knowledge Based System
KC	K-means Clustering
K-NN	k-Nearest Neighbours
LAN	Local Area Networks
LCC	Latent Class Clustering
LCD	Liquid Cristal Display
LED	Light Emitting Diode
LP	Licence Plate
L.P.R.L.	Ley de Protección de Riesgos Laborales
LSTM	Long Short Term Memory
LTE	Long Term Evolution
MAF	Moving Average Filter
MAP	Maximum a Posteriori estimation

MEMS	Micro Electronic Mechanical Systems
ML	Machine Learning
MNL	Multinomial Logit
MOM	Manufacturing Operation Managemet
MQTT	Message Queuing Telemetry Transport
NB	Naïve Bayes Classifier
NFC	Near Field Communication
NN	Neural Networks
NNC	Nearest Neighbour Classification
OIT	Organización Internacional del Trabajo
ORP	Occupational Risk Prevention
OSHA	Occupational Safety and Health Administration
PRL	Prevención de Riesgos Laborales
PPE	Personal Protective Equipment
RF	Random Forest
RFC	Random Forest Classifier
ROC	Receiver Operating Characteristic Curve
ROS	Received Operating System
RSSI	Received Signal Strength Indicator
SBC	Single Board Computer
SCADA	Supervisory Control and Data Adquisition
SCQ	Safety Climate Questionnaire
SMD	Surface Mount Technology
SPHA	Smart Personal Health Advisor
SSVEP	Steady State Visually Evoked Potential
SST	Seguridad y Salud en el Trabajo
SVM	Support Vector Machine
SVSNHE	Stable Vital Sign and Non-Hostile Environment
SVVS	Smooth Variation in Vital Signs
SW	Sofware
UKF	Unscented Kalman Filter
USB	Universal Serial Bus
VOC	Volatile Organic Compounds

TS Transparent and Stretchable Sensors

Wi-Fi Wireless-Fidelity

Capítulo 1

Introducción



VNiVERSiDAD
D SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

Introducción

El sector industrial, es el principal motor del desarrollo económico y social, por ello es de vital importancia el dotar de las últimas tecnologías disponibles para que los procesos y operarios cada vez dispongan de un mayor control y seguridad en su día a día. La mayor parte de los accidentes que se producen en el ámbito laboral se deben a la falta de medidas de prevención, a la escasa formación en materia de seguridad y a unos sistemas de seguridad obsoletos que no se adaptan tecnológicamente a las necesidades de los entornos laborales actuales. Las tecnologías vestibles o wearables han empezado a desempeñar un papel importante en el entorno laboral, siendo cada vez más activas en la nueva revolución industrial, comúnmente llamada Industria 4.0 (Lasi, Fettke, Kemper, Feld, & Hoffmann, 2014). Los modelos basados en EPIs inalámbricos que incorporan sensores, actuadores o tejidos inteligentes, son capaces de reaccionar en tiempo real ante una situación de riesgo, monitoreando de forma continua los parámetros biométricos del trabajador, detectando impactos externos, choques y proporcionando recomendaciones en tiempo real según la luminosidad, los gases, la temperatura del entorno, etc. Una vez la información se ha recogido, esta es procesada, pudiendo utilizar a su vez técnicas de Machine Learning (Johnson et al., 2016) para la toma de decisiones. Por ello la motivación de este trabajo, es combinar esta tecnología con otras como Edge Computing o Inteligencia Artificial, con el objetivo de mejorar la salud y la seguridad en sectores laborales con alto riesgo de accidentes. Diferentes investigaciones han tenido como objetivo diseñar nuevas herramientas y soluciones para la protección de las personas en su entorno laboral, desarrollando tecnología capaz de monitorizar en tiempo real para mejorar la seguridad y la salud en el trabajo. En esta Tesis se propone generar una plataforma integral que permita por un lado conectar EPIs de forma modular a un concentrador Edge Computing, y por otro lado procesar la información recogida mediante técnicas de Inteligencia Artificial (IA), para obtener una plataforma de apoyo

en la realización de tareas en el trabajo, capaz de evolucionar y aprender. La plataforma inteligente es capaz de evolucionar y aprender integrando las técnicas de Smart Data y IA con las que disminuir la siniestralidad laboral. La gestión y procesamiento de datos por medio de sistemas inteligentes, no solo proporciona sistemas de apoyo a la toma de decisiones capaces de mejorar sus respuestas de forma autónoma, sino que también contribuye a la detección de patrones e inferencia de relaciones entre datos, que escapan a la percepción humana. Garantizando de esta forma la seguridad e integridad de los trabajadores mediante la predicción y notificación temprana de las anomalías detectadas en su entorno.

El presente Capítulo introductorio está estructurado de la siguiente forma. La Sección 1.1 realiza una introducción a los antecedentes del tema objeto de estudio y describe el problema a tratar. La Sección 1.2 expone la hipótesis de trabajo, así como los objetivos de los distintos trabajos de investigación que han llevado a la elaboración de esta Tesis Doctoral. La Sección 1.3 detalla la metodología seguida durante dichos trabajos de investigación. Finalmente, la Sección 1.4 describe la estructura de esta memoria.

En cuanto a la Tesis Doctoral se compone de seis Capítulos estructurados del siguiente modo. El Capítulo 1 corresponde con la actual introducción, en el Capítulo 2 se presenta una revisión del estado del arte, el Capítulo 3 describe las contribuciones resultantes de la investigación llevada a cabo, el Capítulo 4 incluye aquellas publicaciones que forman parte de esta Tesis Doctoral por compendio de artículos, el Capítulo 5 presenta los resultados alcanzados en la investigación y finalmente el Capítulo 6 detalla las conclusiones.

1.1. Descripción del problema

Cada año en el mundo millones de trabajadores sufren accidentes de trabajo que les producen lesiones de diversa gravedad: de carácter leve, grave (con o sin incapacidad permanente) y mortal (Organization & et al., 2021). En cada uno de estos accidentes hay dolor físico y psíquico, pérdida de la capacidad de trabajo, preocupación y sufrimiento en la familia del accidentado y costes económicos para la empresa y la sociedad en general.

La prevención de los accidentes de trabajo requiere la aplicación de varias técnicas entre las que se encuentra la investigación de accidentes, que está dedicada a identificar las

causas que los han producido para definir las medidas más adecuadas para su prevención. Dada su importancia y utilidad, su aplicación está establecida en la Ley 31/1995, de 8 de noviembre, de Prevención de Riesgos Laborales, que en su artículo 16 apartado 3, establece la obligación del empresario de realizar una investigación para detectar las causas de todos los daños a la salud de los trabajadores que se hayan producido. La información obtenida ha de servir también para ajustar la evaluación de riesgos y así aumentar la seguridad.

Según el Ministerio de Trabajo y Economía Social del Gobierno de España en su último informe (de Trabajo y Economía Social, 2021) estadístico de accidentes de trabajo con respecto al período Enero-Diciembre 2021 el número de accidentes de trabajo con baja alcanzó la cifra de 572.448 personas (de los cuales 3.702 accidentes fueron graves y 575 accidentes fueron mortales) mientras que el de accidentes de trabajo sin baja fue de 565.075 personas. Comparando las cifras con el mismo periodo del año anterior, los accidentes con baja experimentaron un aumento del 17,9 % y los accidentes sin baja del 8,9 %. Algunos de estos datos quedan recogidos en la Figura 1.1.

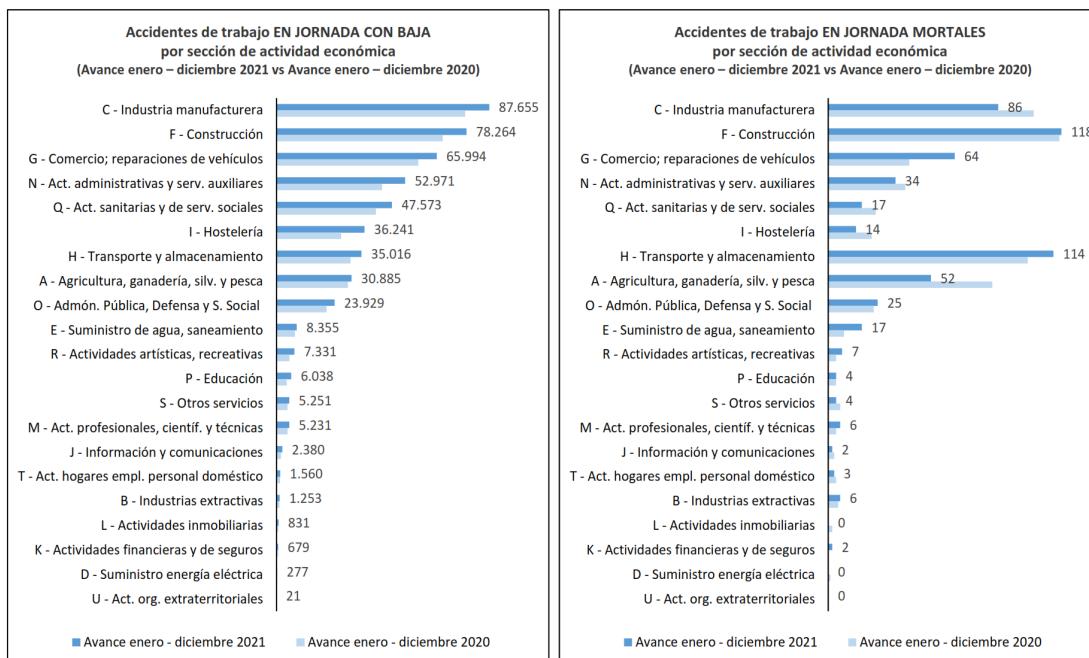


FIGURA 1.1: Estadístico de accidentes de trabajo con respecto al período Enero-Diciembre 2021. (de Trabajo y Economía Social, 2021)

La Organización Internacional del Trabajo (OIT) calcula que cada año unos 2,3 millones de personas en todo el mundo fallecen a causa de accidentes o enfermedades laborales; esto equivale a más de 6.000 muertes diarias. Además se producen 340 millones de

accidentes laborales y 160 millones de víctimas de enfermedades relacionadas con el trabajo, y las actualizaciones indican un aumento de los accidentes y la mala salud. Sin embargo, las estadísticas muestran que las lesiones de los trabajadores pueden variar en función de su sexo y nacionalidad. Los países del primer mundo, con más regulaciones y trabajos menos peligrosos, tienen una tasa de mortalidad menor en comparación con los países subdesarrollados, que también suelen no hacer un seguimiento de las lesiones o muertes en el lugar de trabajo (Shahnavaz, 1987). Por ejemplo, en Estados Unidos, la tasa de incidencia del total de casos registrables de la Administración de Seguridad y Salud Ocupacional (Occupational Safety and Health Administration - OSHA) se mantuvo en 2,8 por cada 100 trabajadores a tiempo completo y se registraron un total de 5333 muertes laborales en 2019 según la Oficina de Estadísticas Laborales de Estados Unidos. Esto hace necesario investigar y desarrollar tecnologías que sustituyan o protejan a los individuos en el trabajo. El impacto de las leyes de seguridad, las regulaciones de los programas de seguridad y las normas de registro de lesiones laborales es de gran importancia. Unas reglas y normas eficaces pueden reducir significativamente los índices de accidentes y lesiones, lo que afecta a las empresas y a la economía (Friend & Kohn, 2018). Diferentes estudios demuestran la importancia de que los organismos estatales y federales consideren la adopción de normas de seguridad laboral (Smitha, Kirk, Oestenstad, Brown, & Lee, 2001) por el impacto que estas leyes tienen en la frecuencia de las lesiones laborales notificadas y la consiguiente mejora de las condiciones de los trabajadores (Boden & Ruser, 2003).

Esta elevada tasa de siniestralidad y la tendencia al alza que registra viene registrando en los últimos años evidencian la gran necesidad que existe en el mundo de abordar el ámbito de la prevención, la seguridad y la salud laboral. Desde la Asociación de Empresas de Equipos de Protección Individual (ASEPAL), denuncian que “España adolece de un déficit preventivo en materia de seguridad laboral, algo que hace aumentar el riesgo de sufrir accidentes laborales cuando la prevención es la primera barrera”. Esta situación ya fue alertada tanto por la Comisión Europea como por el Banco Central Europeo (BCE), que en línea con el “Benchmarking Working Europe 2018” (de Trabajo y Economía Social, 2021), denunciaba que aún queda camino por recorrer para alcanzar los niveles previos a la crisis, siendo la formación e inversión en prevención, seguridad y salud, la única forma de acortar esta brecha.

Este mismo informe respecto al período Enero-Diciembre 2021 sitúa en primer lugar los

problemas físicos derivados de sobreesfuerzos que afectan al sistema musculo-esquelético, como la principal causa de ausencia laboral con más de 156.600 casos, tal como se puede observar en la Figura 1.2. Además, si tenemos en cuenta que los sectores que mayores incidencias registran pertenecen al sector industrial (manufactura) con 87.665 accidentes y la reparación de vehículos a motor, con 78.274, parece claro que es imprescindible desarrollar un conjunto de actuaciones en este tipo de entornos, con el objeto de atajar los problemas y situaciones que se dan de forma más acusada, y lograr alcanzar un gran impacto que permita rebajar estas alarmantes cifras.

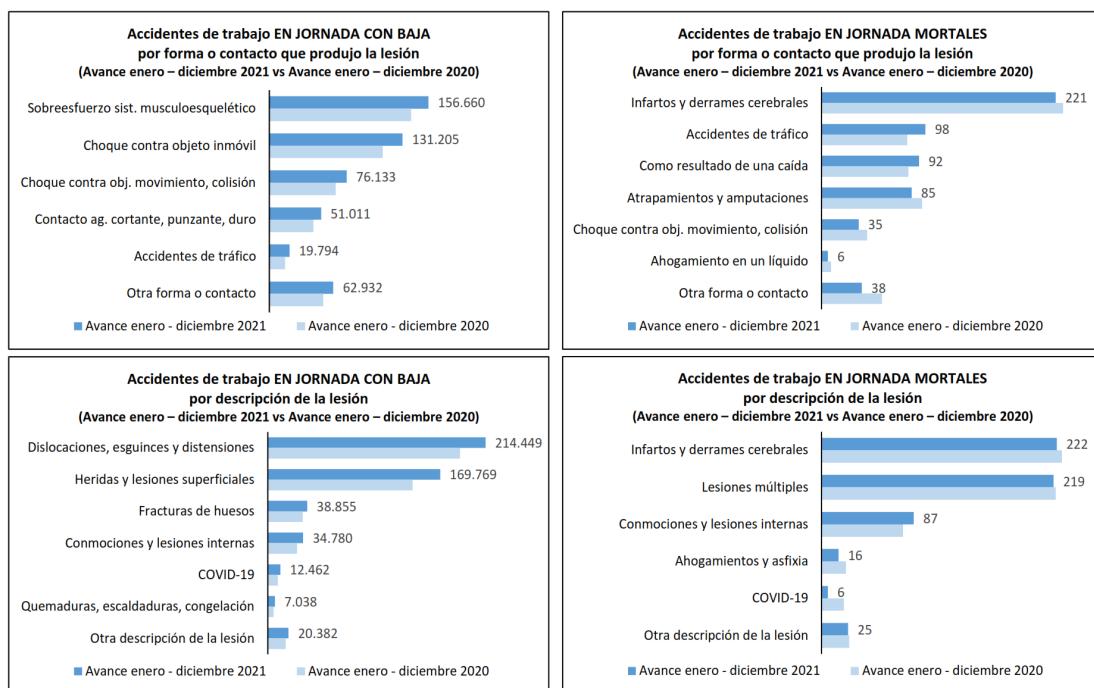


FIGURA 1.2: Estadístico de accidentes de trabajo con respecto al período Enero-Diciembre 2021 (de Trabajo y Economía Social, 2021)

Entre las causas de la elevada tasa de siniestralidad y la tendencia al alza que muestran los estudios, se puede extraer que los motivos vienen derivados de los ajustes presupuestarios, precariedad laboral y temporalidad precedido de una larga época de crisis, que ha alentado la contratación de personal con menor nivel de preparación y con ello, el aumento de la siniestralidad laboral. La reducción de costes en todos los ámbitos ha repercutido en una falta de formación e información en materia de riesgos laborales, materia fundamental para evitar accidentes y garantizar la seguridad y salud en el trabajo. Por ello, es vital adaptar los equipos y sistemas tradicionales utilizados en el entorno laboral al nuevo paradigma tecnológico para que la industria esté conectada y, al mismo tiempo, los trabajadores estén lo más seguros y protegidos posible.

En los últimos años, la disponibilidad de dispositivos wearables del Internet de las Cosas (IoT) se ha incrementado debido a la reducción de costes en la producción de tecnología y haciéndolos más accesibles al público, provocando un gran interés en el estudio de este tema entre la comunidad científica. Esta accesibilidad unida a la revolución del IoT nos permite acceder a la compleja mecánica de algunos entornos de trabajo y reaccionar rápidamente ante un peligro inminente. La integración de estos sistemas pretende crear un ecosistema de EPIs inteligentes para preservar la integridad de los trabajadores, reducir la tasa de accidentes y enfermedades profesionales. Estos equipos deben adaptarse a las necesidades de los trabajadores, proporcionándoles protección sin impedirles realizar sus tareas con normalidad(Akbar-Khanzadeh, Bisesi, & Rivas, 1995; Chabot et al., 2019). Este aspecto es crucial para una aplicación eficaz de los sistemas, ya que un dispositivo incómodo o voluminoso disuadiría a los trabajadores de su uso. Por ello, la tecnología que mejor se adapta a estos requisitos es la tecnología wearable o vestible, que permite llevarla como un accesorio o prenda más.

Los sistemas capaces de monitorizar el estado de los trabajadores y el entorno son necesarios para garantizar las condiciones de seguridad y también pueden integrarse con otras líneas relacionadas con la producción, la planificación de recursos empresariales (Enterprise resource planning - ERP), etc. Hay pocos ejemplos de plataformas que ofrezcan un apoyo integral a los trabajadores, y los que encontramos son muy específicos para cada industria. En este sentido, nuestra plataforma pretende satisfacer las necesidades de cualquier industria a través de un diseño modular y escalable, teniendo la capacidad de interoperar diferentes dispositivos de protección individuales, permitiendo la visualización en tiempo real y la detección temprana de cualquier anomalía utilizando la tecnología Inteligencia artificial de las cosas (Artificial Intelligence and the Internet of Things – AioT) o de inteligencia artificial aplicada a los dispositivos IoT. La plataforma incorpora un sistema de datos inteligente capaz de dar respuestas inteligentes, algoritmos de fusión y procesos de minería de datos de los diferentes dispositivos conectados y una base de conocimiento que reduce el impacto de las anomalías. Gracias a su diseño, la plataforma facilita la incorporación de nuevas soluciones verticales integradas en el diseño horizontal de la plataforma (Heras et al., 2012; Shawish & Salama, 2014). Asimismo, con el uso de tecnologías como el la computación al borde o Edge Computing, es posible plantear entornos capaces de procesar la información a nivel de dispositivo, realizando un preprocesamiento, eliminando el ruido así como gestionando los datos de forma más

eficiente y racional (Shi, Cao, Zhang, Li, & Xu, 2016; Shi & Dustdar, 2016). Igualmente, los nodos pueden actuar de forma autónoma, comunicándose con la plataforma de forma ad hoc cuando se requieran sus servicios. También permite introducir capas de seguridad entre la plataforma y los nodos, lo que aumenta la fiabilidad de los datos. Gracias a las capacidades complementarias de la plataforma (capacidad de extracción e integración de la información, capacidad de aprendizaje y de generación de nuevas reglas a partir del conocimiento adquirido, alta capacidad de procesamiento de datos brutos), se mejora la calidad de la información obtenida. Permiten que la plataforma no solo procese los datos, sino que los comprenda al realizar las tareas (Satyanarayanan, 2017).

1.2. Hipótesis y objetivos

Uno de los principales objetivos de diversas empresas entre el sector industrial es la reducción de accidentes, que van desde lesiones leves hasta la muerte de los trabajadores. Para la prevención de riesgos previamente afectados, se ha optado por la fusión de las tecnologías del Internet de las Cosas y la Industria 4.0, siendo herramientas clave para la detección y notificación al personal de anomalías detectadas en el entorno, generando Equipos de Protección Individual (EPI) con capacidad de predecir, detectar y reportar anomalías en el entorno. Con la generación de estos dispositivos se busca contribuir a la seguridad y salud en el trabajo (SST) con herramienta que consigan un impacto en la reducción de la probabilidad de sufrir enfermedades, lesiones, bajas por accidentes en jornada laboral o accidentes mortales que impidan el desempeño del trabajador durante su actividad diaria (Grant, Christianson, & Price, 2007; Leonavičiūtė, Dėjus, & Antuchevičienė, 2016). Asimismo, aporta aspectos de la aplicación de sistemas inteligentes enfocados a la detección precoz de riesgos en el entorno del trabajador a lo largo de la adición de modelos encargados de predecir o notificar la presencia de riesgos detectados con una mayor precisión (S. M. Sánchez, 2019; S. M. Sánchez et al., 2019). Por ello, es imprescindible notificar estos resultados al trabajador o personal, por lo que se incorporan componentes de comunicación para transmitir y recibir la información entre el sistema electrónico y las técnicas de Cloud y Edge Computing (M. Sánchez, Rodríguez, Manuel, & et al., 2020; S. M. Sánchez et al., 2020).

Por tanto, la hipótesis de partida es que es posible mejorar la seguridad y salud en el entorno laboral, proporcionando herramientas innovadoras materializadas en forma de

equipos de protección individual (o EPIs) con capacidad de responder en tiempo real a los riesgos presentes en los puestos de trabajo en combinación de una plataforma Edge-AIoT, personalizable y adaptable tanto al entorno, como a las circunstancias personales y a las capacidades de cada trabajador.

Como parte de las tareas de investigación ha sido necesario especificar y definir los requisitos de la plataforma a desarrollar con el objeto de identificar las situaciones de riesgo comunes que pueden generalizarse para cada uno de los dispositivos. Para ello, se hizo necesario definir un conjunto de acciones acotado, buscando lograr el mayor impacto posible. Dentro de la gran cantidad de información en este contexto, se llevó a cabo un análisis de las recomendaciones que aparecen en los reglamentos y manuales de prevención de riesgos para saber cuáles son susceptibles de ser incluidas por presentar una mayor compatibilidad con los dispositivos desarrollados. En base a esto, se definieron las funcionalidades que incorporar, así como los medios técnicos necesarios para su implementación, que se ha materializado por medio del diseño de una plataforma, la definición de los componentes y la correcta identificación del flujo de la información a través de los diferentes módulos y nodos. A partir de la formalización del modelo, se han creado las reglas de asociación de los riesgos con un conjunto de medidas preventivas dado el contexto de la situación.

Así, el **objetivo principal** de esta Tesis Doctoral es investigar, diseñar, desarrollar e implementar una plataforma integral que de soluciones que permitan cubrir todo el rango de actuación de la Prevención de Riesgos Laborales (PRL) utilizando mecanismos inteligentes basados en diferentes modelos de Inteligencia Artificial integrados en una plataforma Edge Computing diseñada para el despliegue de dispositivos de forma modular.

Para alcanzar el objetivo principal, es necesario concretar un listado de **objetivos específicos**, que se describen a continuación:

- (OB1) Identificar las situaciones de riesgo comunes con los cuales definir las funcionalidades de la plataforma y requisitos que deben incorporarse.
- (OB2) Investigar los factores que permiten caracterizar el nivel de riesgo de una actividad en función del contexto, del trabajador y de los procedimientos que aplica.

- (OB3)** Investigar en el diseño de nuevas herramientas y soluciones para la monitorización y protección de las personas en su entorno de trabajo, basadas en electrónica wearable y tejidos inteligentes, para su incorporación en EPIs.
- (OB4)** Investigar y diseñar los equipos y sistemas auxiliares de detección, aviso e identificación de riesgos, que puedan integrarse en los diferentes dispositivos.
- (OB5)** Investigar sobre técnicas y metodologías sobre el tratamiento de los datos recogidos en los sensores. Uso de análisis de datos, algoritmos de prevención y el uso de la plataforma de control.
- (OB6)** Integrar las prestaciones que proporciona el AIoT y Smart Data para obtener una plataforma de apoyo en el desempeño de la actividad, capaz de evolucionar y aprender.
- (OB7)** Diseñar la plataforma modular Edge AIoT escalable, para la ingestión de datos de diferentes dispositivos, que incorpore algoritmos de Inteligencia Artificial para la detección, diagnóstico y el control predictivo de situaciones de riesgo en entornos laborales.
- (OB8)** Validar la plataforma en diferentes entornos de trabajo para el análisis y evaluación del correcto desempeño de los resultados obtenidos.

1.3. Metodología de investigación

El proceso de investigación ha exigido la aplicación de diferentes metodologías ágiles que permita ofrecer las máximas garantías en la obtención de los resultados alineados con la hipótesis y objetivos de partida. Se ha seguido un proceso que pasa por una serie de etapas: Análisis, Requerimientos del Sistema, Investigación y Diseño, Integración de las Soluciones y Pruebas y Validación. La planificación de metas parciales dentro de plazos establecidos, junto con el diseño de unas métricas personalizadas que permitan evaluar los resultados, son las herramientas fundamentales que se han utilizado para validar los progresos de cada una de estas etapas, integrando en el proceso las conclusiones alcanzadas, para poder avanzar en la elección de nuevas metas. Y que permite garantizar que los pasos que se dan en el proceso se orientan hacia la consecución de los objetivos parciales planteados.

La implementación de esta metodología ha permitido un correcto seguimiento de la investigación y dotar de herramientas para verificar el adecuado progreso de esta y la óptima calidad de los resultados obtenidos. Dentro de los cometidos cumplidos, destacan:

1. La adecuada sintonía entre las acciones y problemas planteados.
2. La normalización de los pasos, etapas y fases a cumplimentar.
3. La apropiada gestión y garantía de la calidad de los resultados obtenidos.

De forma recurrente, en cada una de estas etapas, se aplica un protocolo que cubre varias acciones y que se itera en cada fase. Este conjunto de acciones responde a la ampliamente extendida metodología Action-Research (traducida al castellano habitualmente como Investigación-Acción), que se aplica de forma generalizada en este tipo de plataformas en el ámbito científico-técnico:

1. Identificación del problema que se pretende abordar.
2. Formulación de hipótesis a partir de un modelo que se construye en torno a conceptos y conocimientos adquiridos y validados en un escenario real cuantificado.
3. Aplicación de este modelo al nuevo escenario al que se quiere dar respuesta.
4. Análisis de la información generada.
5. Extracción de conclusiones fruto de la evaluación razonada de los datos obtenidos.
6. Formulación de nuevos conceptos que sirvan para alimentar la siguiente iteración del proceso de investigación.
7. El exhaustivo control de tareas y procesos desarrollados.
8. Y la minimización de los riesgos inherentes a la investigación.

(Baskerville, 1999) indica que la metodología Action-Research permite encontrar un mayor realismo al involucrar un contexto real para investigar los resultados de acciones concretas. En base a la investigación-acción se han considerado cinco fases para el desarrollo de esta Tesis Doctoral (Eden & Ackermann, 2018; Tüzün, Tekinerdogan, Macit, & İnce, 2019), que se describen a continuación:

1. **Diagnóstico:** Dentro de esta fase se realiza la identificación y planteamiento del problema expuesto en esta Tesis Doctoral. Inicialmente se debe delimitar el alcance, posteriormente se propone una hipótesis y en último lugar se definen los objetivos que se pretenden alcanzar. A este respecto, se recopilaron y analizaron las normativas, reglamentos y manuales de Prevención de Riesgos Laborales (PRL) para identificación de las situaciones que presentan una mayor incidencia en la seguridad de forma que se agrupen por actividad-sector.
2. **Revisión de la literatura:** Se lleva a cabo el estudio del estado del arte con el objeto de establecer las soluciones existentes y marcar las bases para el diseño de una solución innovadora al problema planteado. En este trabajo de investigación se incluye una revisión del estado del arte en sensores, actuadores, elementos de protección y tecnologías aplicables para el procesamiento y análisis de los datos con los cuales poder atajar los peligros que se identificaron.
3. **Solución:** A partir de los resultados conseguidos en las dos fases anteriores, se presenta una solución que cumpla con los objetivos establecidos. En esta Tesis Doctoral se plantea integración dentro del sistema distintas opciones Hardware (HW) a través de redes de sensores en equipos de protección individual (EPIs) y Software (SW) mediante la plataforma que combina las estrategias de Inteligencia Artificial e Internet de las Cosas (AIoT) con la adquisición de datos en tiempo real para generar conocimiento valioso y que permitan cumplir las expectativas de los usuarios potenciales.
4. **Evaluación:** En esta fase se lleva a cabo la evaluación de la plataforma planteada en diferentes escenarios para la validación del sistema y mejora de la funcionalidad diseñada.
5. **Resultados:** Comprende la última fase del ciclo de investigación-acción. Por medio de las actividades de esta etapa, la comunidad científica valora los resultados obtenidos en base a un diferentes de publicaciones evaluadas en revistas de alto impacto, incluyendo Computer Communications, Sensors, Sustainability o Electronic Engineering, así como congresos y conferencias internacionales, como la International Conference on Soft Computing Models in Industrial and Environmental Applications o la International Conference on Practical Applications of Agents and Multi-Agent Systems, entre otras.

1.4. Estructura de la Tesis Doctoral

La Tesis Doctoral pretende proporcionar una plataforma referencia al servicio de la industria conectada que permita dotar de nuevas capacidades para mejorar la seguridad en la realización de procesos, análisis predictivo y visualización en tiempo real, integrando toda la información relevante generada por los diferentes equipos de protección, así como la incorporación de las diferentes fuentes de datos resultantes de la actividad, y asegurando la compatibilidad futura con las nuevas fuentes de información, soluciones y dispositivos del Internet de las Cosas (IoT) que puedan implementarse.

Con el objeto de demostrar la hipótesis de la investigación y abordar los objetivos establecidos. Inicialmente se ha llevado a cabo una identificación las situaciones de riesgo comunes con los cuales definir las funcionalidades de la plataforma y requisitos que deben incorporarse (OB1) con los cuales caracterizar el nivel de riesgo de una actividad en función del contexto, del trabajador y de los procedimientos que aplica (OB2). Posteriormente se ha realizado una revisión del estado del arte existente en tecnologías IoT, Edge Computing, Inteligencia Artificial, incluyendo el análisis de los retos actuales de aplicación de estas tecnologías en el entorno laboral para la Prevención de Riesgos Laborales (PRL) (OB3).

Tras ello, se detallan las contribuciones llevadas a cabo en esta Tesis Doctoral. A continuación, se detallan cada una de ellas:

- Por un lado, en el primer artículo se describe el uso de un Casco Inteligente, para ser utilizado en un entorno de Internet Industrial de las Cosas que utiliza inteligencia artificial y analiza el estado de los trabajadores y entorno, y además se encarga de realizar una evaluación de riesgos en tiempo real (OB4).
- Por otro lado, se detallan el procesamiento en una arquitectura Cloud para hacerlos aptos para el procesamiento mediante Deep Convolutional Neural Network (CNN) y los resultados se comparan con otros modelos como el Static Neural Network (NN), Naïve Bayes Classifier (NB) y Support Vector Machine (SVM) (OB5).

En las siguientes contribuciones científicas se plantean plataformas donde se realiza una investigación sobre las técnicas y metodologías de tratamiento de datos (OB5), así como el diseño de los equipos y sistemas auxiliares de detección (OB3).

- En el caso de BeSafe B2.0, se presenta una plataforma que combina un sistema híbrido DE Modelo de mezcla gaussiana (Gaussian Mixture Model - GMM) y Human Activity Classification (HAC), utilizando con dispositivo para el estudio un Brazalete Inteligente, basadas en electrónica wearable y tejidos inteligentes (OB3). La plataforma integra las prestaciones que proporciona el AIoT y Smart Data para dar apoyo en el desempeño de la actividad, capaz de evolucionar y aprender (OB6).
- Después de toda las investigaciones, como plataforma final se propone un sistema que integra tres Equipos de protección Individual (EPIs): casco, brazalete y cinturón. El sistema provee la información al trabajador utilizando diferentes técnicas de inteligencia artificial combinadas con Edge Computing (OB7). El diseño modular de la plataforma y su adaptabilidad permite la validación del sistema en diferentes entornos para el análisis y evaluación del correcto desempeño de los resultados obtenidos (OB8).

La estructura de esta Tesis Doctoral por compendio de artículos/publicaciones incluye la presentación de las evidencias y resultados originados en el trabajo de investigación llevado a cabo durante la elaboración de esta Tesis Doctoral, así como las publicaciones acreditativas de la investigación realizada. Finalmente, se exponen las conclusiones y las líneas de trabajo futuras.

De este modo, y tal como se ha adelantado, con el fin de facilitar el seguimiento de la investigación, se estructura la memoria de la presente Tesis Doctoral a través de seis Capítulos. El primero de ellos corresponde con la actual Capítulo 1 (“Introducción”), en la que se describe el problema a resolver planteado, se formula la hipótesis de trabajo, se detallan los diferentes objetivos y se describe la metodología de investigación seguida para la culminación de esta Tesis Doctoral.

El Capítulo 2 presenta una revisión del estado actual del arte en seguridad en el trabajo en la Sección 2.2, IoT aplicado a EPIs, Wearables y Textiles Inteligentes en la Sección 2.3, integración de IA en la Sección 2.4, plataformas y arquitecturas para la prevención en la Sección 2.5 y por último unas conclusiones en la Sección 2.6, mostrando las diferentes innovaciones en cada uno de estos ámbitos.

El Capítulo 3 describe las contribuciones resultantes de la investigación llevada a cabo y que se compendia en esta Tesis Doctoral. Se detalla y describe el sistema para diferentes escenarios de uso y con diferentes dispositivos EPI. También se comparan diferentes modelos de Inteligencia Artificial para el análisis de datos en tiempo real, además de realizar un reconocimiento de la actividad humana que combinado con otros algoritmos de aprendizaje no supervisado permitan detectar anomalías. Gracias al conocimiento adquirido, se presenta finalmente una plataforma Edge Computing modular que permite adaptarse al entorno y conectar multitud de dispositivos con diferentes tecnologías de comunicación.

El Capítulo 4 (“Publicaciones acreditativas de la investigación realizada”) explica el sistema integral Edge-AIoT e incluye aquellas publicaciones que forman parte de esta Tesis Doctoral por compendio de artículos, acompañadas, cada una de ellas, por su correspondiente introducción, conjunto de objetivos, descripción de la metodología de investigación utilizada en cada una, así como las conclusiones de los resultados obtenidos en cada una de dichas publicaciones.

El Capítulo 5 (“Evidencias y resultados”) presenta los resultados alcanzados mediante el desarrollo de la investigación que culmina en esta Tesis Doctoral y que se validan a través de un conjunto de publicaciones en revistas científicas, conferencias, congresos, Capítulos de libro y workshops internacionales en los cuales se ha contribuido, así como los proyectos de investigación en los que se ha participado. Asimismo, se detallan las estancias llevadas a cabo en organismos de investigación internacionales en el transcurso de las investigaciones que se comprendían en esta Tesis Doctoral.

Finalmente, el Capítulo 6 detalla las conclusiones más importantes que se han obtenido a partir del trabajo desarrollado dentro de la investigación en esta Tesis Doctoral y aquellas aportaciones más significativas realizadas. Además, se definen las líneas de interés para continuar el desarrollo como trabajo futuro que se generan a partir de los resultados obtenidos en la presente Tesis Doctoral. Para concluir, se añade un listado completo de todas las fuentes bibliográficas que se han utilizado como referencia y se citan dentro de la Tesis Doctoral, que han servido como apoyo y permiten respaldar las afirmaciones y conceptos presentados.

Chapter 1

Introduction



VNiVERSiDAD
D SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

Introduction

The industrial sector is the main driver of economic and social development. Therefore, it is of vital importance to equip it with the latest available technologies so that processes and operators can enjoy greater control and safety in their daily work. Most accidents that occur in the workplace are due to a lack of prevention measures, poor safety training and obsolete safety systems that are not technologically adapted to the needs of today's workspaces. Wearable technologies or wearables have started to play an important role in the work environment and are becoming more prominent in the new industrial revolution, commonly referred to as Industry 4.0 (Lasi et al., 2014). Models based on wireless PPE that incorporates sensors, actuators or smart fabrics, are able to react to a risk in real time, continuously monitoring the biometric parameters of the worker, detecting external impacts, shocks and providing real-time recommendations which take into account factors such as luminosity, gases, the temperature of the environment, etc. Once the information has been collected, it is processed, and Machine Learning techniques (Johnson et al., 2016) may be used for decision-making. Therefore, the motivation of this work is to combine this technology with others such as Edge Computing or Artificial Intelligence, with the aim of improving health and safety in occupational sectors that have a high risk of accidents. Different studies have aimed to design new tools and solutions for the protection of people in their working environment, developing technology capable of real-time monitoring to improve safety and health at work. In this Thesis, an integral platform is proposed that allows to connect PPEs in a modular way to an Edge Computing concentrator. Moreover, the platform processes the collected data by means of Artificial Intelligence (AI) techniques, providing support to the workers in the performance of tasks. This intelligent platform is able to evolve and learn by integrating Smart Data and AI techniques to reduce work-related accidents. The management and processing of data by means of intelligent systems not only provides

decision support systems capable of improving their responses autonomously but also contributes to the detection of patterns and relationships between data, which could be overlooked by humans. Thus, ensuring the safety and integrity of workers through prediction and early warnings regarding the anomalies detected in their environment.

This introductory chapter is structured as follows. Section 1.1 introduces the background to the subject under study and describes the problem to be addressed. Section 1.2 states the working hypothesis, as well as the objectives of the different research studies that have led to the elaboration of this Doctoral Thesis. Section 1.3 details the methodology followed during the research activities. Finally, Section 1.4 describes the structure of this dissertation.

The Doctoral Thesis is composed of six chapters structured as follows. Chapter 1 corresponds to the current introduction, Chapter 2 reviews the state of the art, Chapter 3 describes the contributions resulting from the research carried out, Chapter 4 includes the compendium of publications that are a part of this Doctoral Thesis, Chapter 5 presents the results achieved in the research, and finally, Chapter 6 draws conclusions from the conducted research.

1.1. Problem description

Globally, every year millions of workers suffer occupational accidents that cause injuries of varying severity: minor, serious (with or without permanent disability) and fatal (Organization & et al., 2021). In each of these accidents, there is physical and psychological pain, loss of working capacity, concern and suffering for the family of the injured person and economic costs for the company and society in general. The prevention of occupational accidents requires the application of several techniques, among which is accident investigation, which is dedicated to identifying the causes that have produced them in order to define the most appropriate measures for their prevention. Given the importance and usefulness of this approach, its use is established in Law 31/1995, of November 8, 1995, on the Prevention of Occupational Risks, which establishes in Article 16 Section 3, the obligation of the employer to carry out an investigation to detect the causes of any damage to the health of their workers. The obtained information must also be used to adapt the risk assessment in order to

increase safety. According to the latest statistical report on occupational accidents for January-December 2021 period, of the Spanish Ministry of Labor and Social Economy (de Trabajo y Economía Social, 2021), the number of occupational accidents with sick leave reached 572,448 people (of which 3,702 were serious accidents and 575 were fatal) while the number of occupational accidents without sick leave was of 565,075 people. Comparing the figures with the same period from the previous year, accidents with sick leave increased by 17,9% and accidents without sick leave by 8,9%. Some of these data are shown in Figure1.1.

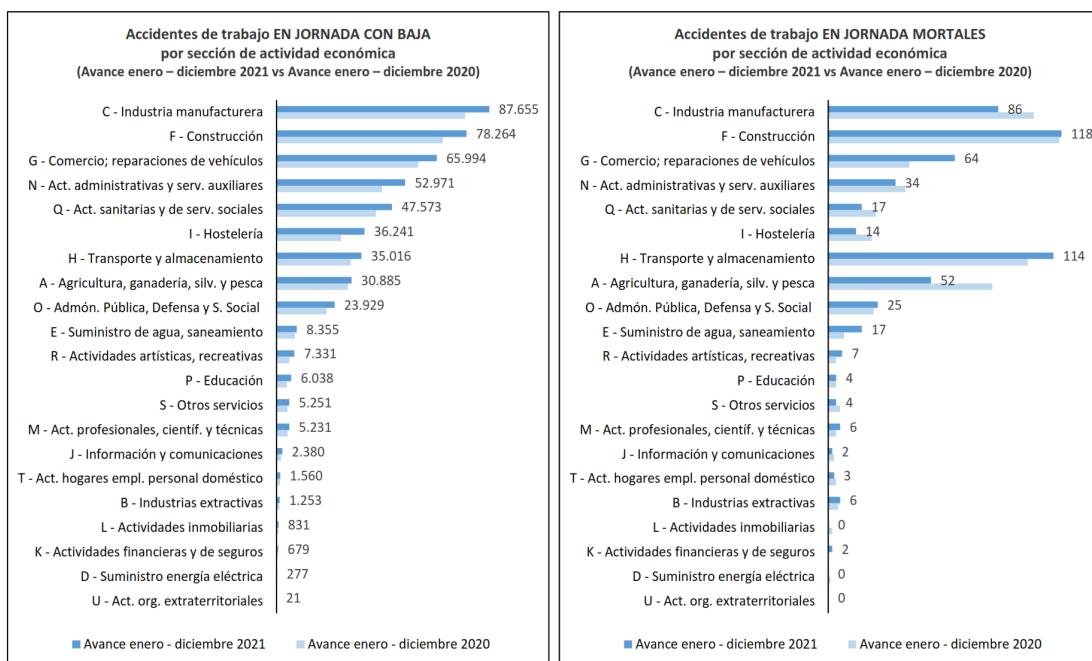


FIGURE 1.1: Occupational accident statistics for the period January-December 2021.
Ministry of Labor and Social Economy (de Trabajo y Economía Social, 2021)

The International Labor Organization (ILO) estimates that each year approximately 2.3 million people worldwide die as a result of occupational accidents or illnesses; this is equivalent to more than 6,000 deaths per day. In addition, there are 340 million occupational accidents and 160 million victims of work-related diseases, and updates indicate an increase in accidents and ill health. However, statistics show that worker injuries can vary according to gender and nationality. First-world countries, with more regulations and less hazardous jobs, have a lower fatality rate compared to underdeveloped countries, which also tend not to track workplace injuries or deaths (Shahnavaz, 1987). For example, in the United States, the incidence rate of total Occupational Safety and Health Administration (OSHA) recordable cases stood at 2.8 per 100 full-time workers and a total of 5333 occupational fatalities were recorded in 2019

according to the U.S. Bureau of Labor Statistics. This makes it necessary to research and develop technologies that replace or protect individuals in the workplace. Safety laws, safety program regulations, and occupational injury recording standards have a significant impact. Effective rules and regulations can considerably reduce accident and injury rates, which affects businesses and the economy (Friend & Kohn, 2018). Different studies demonstrate the importance of state and federal agencies considering the adoption of workplace safety standards (Smitha et al., 2001) because of the impact these laws have on the frequency of reported workplace injuries and the resulting improved conditions for workers (Boden & Ruser, 2003).

This high accident rate and the upward trend that has been recorded in recent years are evidence of the great need that exists in the world to address the field of prevention, safety and occupational health. The Association of Personal Protective Equipment Companies (ASEPAL) denounces that "Spain suffers from a preventive deficit in terms of occupational safety, something that increases the risk of suffering accidents at work when prevention is the first barrier". This situation has already been alerted by both the European Commission and the European Central Bank (ECB), which, in line with the "Benchmarking Working Europe 2018" (de Trabajo y Economía Social, 2021), reported that there is still a long way to go to reach pre-crisis levels, with training and investment in prevention, safety and health being the only way to bridge this gap.

The same report for the period January-December 2021 situates in first place the physical problems derived from overexertion affecting the musculoskeletal system, as the main cause of absence from work, with more than 156,600 cases, as can be seen in Figure1.2. Furthermore, if we take into account that the sectors with the highest number of incidents belong to the industrial sector (manufacturing) with 87,665 accidents and the repair of motor vehicles, with 78,274, it seems clear that it is essential to develop a set of actions aimed at this type of environment, in order to tackle the problems and situations that occur most markedly, and to achieve a major impact that will reduce these alarming figures.

Among the causes of the high accident rate and the upward trend shown by the studies, it can be deduced that primary causes of accidents derive from budgetary adjustments, job insecurity and temporary employment preceded by a long period of crisis, which has led to the hiring of personnel with a lower level of training and with it, the increase in

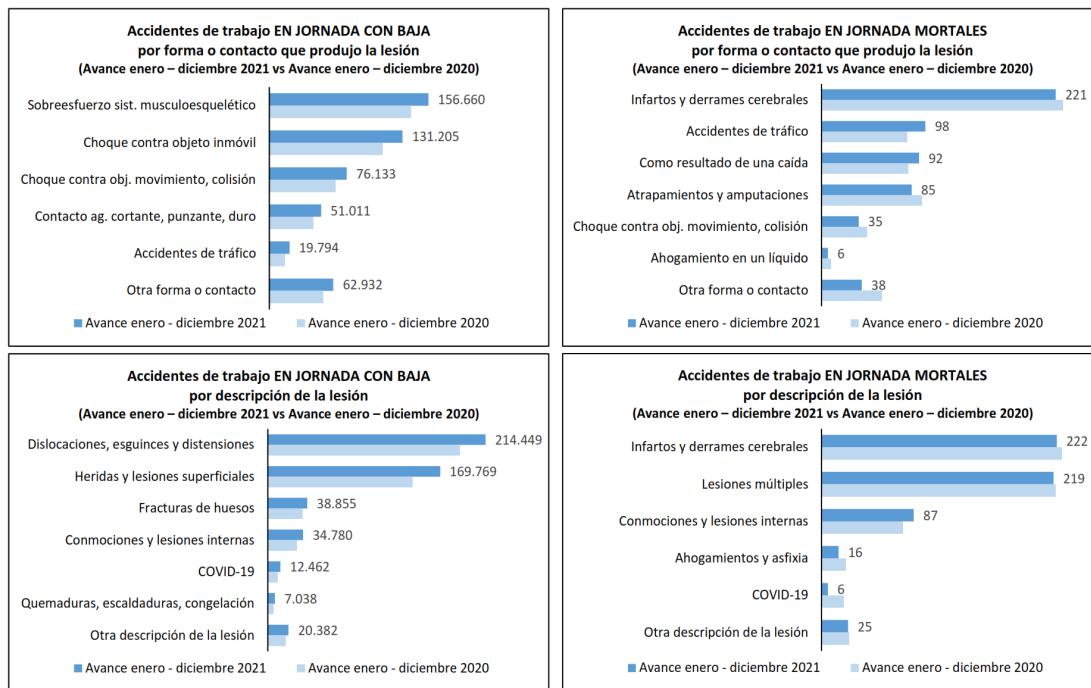


FIGURE 1.2: Occupational accident statistics for the period January-December 2021
(de Trabajo y Economía Social, 2021)

accident rate at work. The reduction of costs in all areas has led to a lack of training and information on occupational hazards, which is essential to prevent accidents and ensure health and safety at work. It is therefore vital to adapt the traditional equipment and systems used in the working environment to the new technological paradigm so that the industry is connected, and, at the same time, workers are as safe and protected as possible. In recent years, the cost of wearable Internet of Things (IoT) devices has reduced, making them more accessible to the public. This, in turn, has led to great interest in this topic among the scientific community. Accessibility coupled with the IoT revolution makes it possible to access the complex mechanics of some working environments and react quickly to imminent danger. The integration of these systems aims to create an ecosystem of intelligent PPE designed to safeguard the integrity of workers, reduce the rate of accidents and occupational diseases. This equipment must be adapted to the needs of workers, providing them with protection without preventing them from performing their tasks normally(Akbar-Khanzadeh et al., 1995; Chabot et al., 2019). This aspect is crucial for an effective implementation of the systems, as an uncomfortable or bulky device would deter workers from using it. Therefore, the technology that best meets these requirements is wearable technology, which can be worn as an accessory or garment.

Systems capable of monitoring the status of workers and the environment are necessary to ensure safety conditions and can also be integrated with other operational processes related to production, ERP, etc. There are few examples of platforms that offer comprehensive support to workers, and those that do, are very specific to each industry. In this regard, our platform aims to meet the needs of any industry through a modular and scalable design, having the ability to interoperate different individual protection devices, allowing for real-time visualization and early detection of any anomaly using Artificial Intelligence and the Internet of Things (AioT) or Artificial Intelligence technology applied to IoT devices. The platform incorporates an intelligent data system capable of delivering intelligent responses, fusion algorithms and data mining processes of the different connected devices and a knowledge database that reduces the impact of anomalies. Thanks to its design, the platform facilitates the incorporation of new vertical solutions integrated into the platform's horizontal design (Heras et al., 2012; Shawish & Salama, 2014). Likewise, with the use of technologies such as Edge Computing, it is possible to propose environments capable of processing information at the device level, performing preprocessing, eliminating noise and managing data on a more efficient and rational basis (Shi et al., 2016; Shi & Dustdar, 2016). Similarly, nodes can act autonomously, communicating with the platform on an ad hoc basis when their services are required. It also allows to introduce layers of security between the platform and the nodes, which increases the reliability of the data. Thanks to the platform's complementary capabilities (information extraction and integration capacity, capacity to learn and generate new rules based on the acquired knowledge, high raw data processing capacity), the quality of the obtained information is improved. These features allow the platform to not only process the data, but also to understand them when performing the tasks (Satyanarayanan, 2017).

1.2. Hypothesis and objectives

Numerous companies within the industrial sector aim to reduce accident rates, which range from minor injuries to death. For the prevention of the previously described risks, the fusion of Internet of Things and Industry 4.0 technologies has been chosen for the development of PPE, as they are key tools with the capacity to predict, detect anomalies in the working environment and report them to the personnel. The purpose

of these devices is to increase occupational safety and health (OSH) by reducing the probability of illnesses, injuries, sick leave due to accidents during working hours or fatal accidents that prevent the worker from performing their daily activities (Grant et al., 2007; Leonavičiūtė et al., 2016). Likewise, intelligent system focus on the early and accurate detection of risks in the worker's environment through the use of models for the prediction and warning against the risks (S. M. Sánchez, 2019; S. M. Sánchez et al., 2019). Therefore, it is essential to notify these results to the worker or staff, so communication components are incorporated to transmit and receive the information between the electronic system and Cloud and Edge Computing techniques (M. Sánchez et al., 2020; S. M. Sánchez et al., 2020).

Therefore, the initial hypothesis is that it is possible to improve safety and health in the working environment through innovative tools in the form of personal protective equipment (or PPE). These tools have the ability to respond to the risks present in the workplace in real-time, thanks to their integration with an Edge-AIoT platform, which can be customized and adapted to both the environment and the personal circumstances and capabilities of each worker.

As part of the research tasks, it was necessary to specify and define the requirements of the platform to be developed in order to identify the common risk situations that can be generalized for each of the devices. For this purpose, it was necessary to define a limited set of actions, seeking to achieve the greatest possible impact. Within the large amount of information available on this subject, an analysis of the recommendations that appear in the regulations and risk prevention manuals was carried out to find out which ones are liable to be included due to their greater compatibility with the developed devices. On this basis, the functionalities to be incorporated were defined, as well as the technical means required for implementation, which has been materialized through the design of a platform, the definition of the components and the correct identification of the flow of information through the different modules and nodes. In the formalization of the model, the rules for associating risks with a set of preventive measures have been created on the basis of the context of the situation.

Thus, the **main objective** of this Doctoral Thesis is to research, design, develop and implement a comprehensive platform that provides solutions to fully cover the extent of Occupational Risk Prevention (ORP) through the use of intelligent mechanisms

based on different Artificial Intelligence models integrated in an Edge Computing platform. The platform has been designed to enable for the modular deployment of devices.

To achieve the main objective, it has been necessary to draw a list of specific objectives, which are described below:

- (OB1)** Identify common scenarios which involve risk, with the aim of defining the platform's functionalities and the functionalities to be incorporated.
- (OB2)** Research the factors that allow to characterize the level of risk of an activity according to the context, the worker and the procedures applied.
- (OB3)** To investigate the design of new tools and solutions for the monitoring and protection of people in their work environment, based on wearable electronics and smart fabrics, for incorporation in PPE.
- (OB4)** Research and design of auxiliary equipment and systems for detection, warning and identification of risks, which can be integrated in different devices.
- (OB5)** Research techniques and methodologies for the processing of data collected from sensors. Use of data analysis, prevention algorithms and the use of the control platform.
- (OB6)** Integrate the features provided by AIoT and Smart Data to obtain a platform that provides operational support and is capable of evolving and learning.
- (OB7)** Design a scalable Edge AIoT modular platform for the ingestion of data from different devices, incorporating Artificial Intelligence algorithms for the detection, diagnosis and predictive control of risk situations in working environments.
- (OB8)** Validation of the system in different working environments for the analysis and evaluation of the correct performance of the obtained results.

1.3. Research methodology

The research process has required the application of different agile methodologies to guarantee that the obtained results are aligned with the hypothesis and initial

objectives. A process has been followed that goes through a series of stages: Analysis, System Requirements, Research and Design, Integration of Solutions, and Testing and Validation. The planning of specific objectives within the established deadlines, together with the design of customized metrics to evaluate the results, were fundamental to validating the progress of each of these stages, integrating the conclusions reached in the process, in order to be able to move forward in the choice of new goals. This makes it possible to guarantee that the steps taken in the process are oriented towards the achievement of the specific objectives set.

The implementation of this methodology has allowed for a correct follow-up of the research and has provided tools for the verification of the correct progress of the research and the optimum quality of the obtained results. Among the accomplished tasks, the following stand out:

1. Correct alignment between the actions and the problems posed.
2. Standardization of the steps, stages and phases to be completed.
3. Appropriate management and quality assurance of the obtained results.

At each of these stages, a protocol covering several actions has been applied and iterated in each phase. This set of actions responds to the widespread Action-Research methodology (usually translated into English as Action-Research), which is commonly applied in this type of platforms in the scientific-technical field:

1. Identification of the problem to be addressed.
2. Formulation of hypotheses based on a model built on concepts and knowledge that have been acquired and validated in a quantified real scenario.
3. Application of this model to the new scenario to be addressed.
4. Analysis of the obtained information.
5. Drawing conclusions from the evaluation of the obtained data.
6. Formulation of new concepts that serve to feed the next iteration of the research process.

7. The exhaustive control of the developed tasks and processes.
8. Minimization of the risks inherent to research.

(Baskerville, 1999) indicates that the Action-Research methodology allows to find a greater level of realism by involving a real context to investigate the results of concrete actions. Following Action-Research, five phases have been considered for the development of this Doctoral Thesis (Eden & Ackermann, 2018; Tüzün et al., 2019), which are described below:

1. **Diagnosis:** In this phase, the identification and statement of the problem presented in this Doctoral Thesis is carried out. Initially the scope must be delimited, then a hypothesis is proposed and finally the objectives to be achieved are defined. In this regard, the norms, regulations and manuals of Occupational Risk Prevention (ORP) were compiled and analyzed to identify the situations that have a greater impact on safety so that they are grouped by activity/sector.
2. **Literature review:** A study of the state of the art has been carried out in order to establish the existing solutions and lay the foundations for the design of an innovative solution to the problem posed. This research work includes a review of the state of the art in sensors, actuators, protection elements and technologies applied in data processing and analysis, looking at their ability to address the identified risks.
3. **Solution** From the results obtained in the two previous phases, a solution that meets the established objectives has been presented. This Doctoral Thesis proposes the integration of different hardware (HW) options through sensor networks in personal protective equipment (PPEs), and software (SW) through a platform that combines Artificial Intelligence and Internet of Things (AIoT) strategies with real-time data acquisition. This results in a platform that obtains valuable knowledge to meet the needs of potential users.
4. **Evaluation:** In this phase, the evaluation of the proposed platform has been carried out in different scenarios to validate the system and improve the designed functionality.

5. Results: This is the last phase of the action research cycle. Through the activities in this stage, the scientific community evaluates the obtained results in the different publications in high impact journals, including Computer Communications, Sensors, Sustainability or Electronic Engineering, as well as international congresses and conferences, such as the International Conference on Soft Computing Models in Industrial and Environmental Applications or the International Conference on Practical Applications of Agents and Multi-Agent Systems, among others.

1.4. Doctoral Thesis structure

The Doctoral Thesis aims to provide a reference platform for the connected industry that will provide new capabilities for improved safety in the carrying out of tasks, through predictive analysis and real-time visualization, integrating all relevant information generated by the protective equipment, as well as the data derived from the different activities. Moreover, the platform ensures compatibility with new sources of information, solutions and devices of the Internet of Things (IoT) that may be implemented in the future.

To demonstrate the research hypothesis and address the established objectives: Initially, an identification of common situations of risk has been carried out to define the platform functionalities to be incorporated (OB1) with which to characterize the level of risk of an activity according to the context, the worker and the procedures to be applied (OB2). Subsequently, a review of the state of the art in IoT technologies, Edge Computing, Artificial Intelligence has been carried out, including the analysis of the current challenges of applying these technologies in the work environment for Occupational Risk Prevention (ORP) (OB3).

Then, the contributions of this Doctoral Thesis are detailed. Each of them is described below:

- The first article describes a Smart Helmet, to be used in an Industrial Internet of Things environment that uses artificial intelligence and analyzes the health condition of the workers and the state of the environment and is also in charge of performing a real-time risk assessment (OB4).

- Furthermore, a Cloud architecture is made suitable for processing using the Deep Convolutional Neural Network (CNN) and the results are compared with other models, such as Static Neural Network (NN), Naïve Bayes Classifier (NB) and Support Vector Machine (SVM) (OB5).

In the following scientific contributions, platforms have been proposed that were oriented towards data processing techniques and methodologies (OB5), as well as the design of equipment and auxiliary detection systems (OB3).

- In the case of BeSafe B2.0, a platform is presented that combines a hybrid system of Gaussian Mixture Model (GMM) and Human Activity Classification (HAC), using a Smart Bracelet as a device for the study, based on wearable electronics and smart fabrics (OB3). The platform integrates the features provided by AIoT and Smart Data to support the performance of tasks, capable of evolving and learning (OB6).
- After all the research, a system that integrates three elements of Personal Protective Equipment (PPE): a helmet, a bracelet and a belt, is proposed as the final platform. The system provides information to the worker using different Artificial Intelligence techniques combined with Edge Computing (OB7). The modular design of the platform and its adaptability allows for the validation of the system in different environments through the analysis and evaluation of the obtained results (OB8).

The structure of this Doctoral Thesis consists of a compendium of articles/publications, including the presentation of the evidence and the results obtained from the research work that has been carried out during the elaboration of this Doctoral Thesis. It also includes the publications that accredit the research that has been carried out. Finally, conclusions and future lines of research are presented.

To facilitate the follow-up of the research, this Doctoral Thesis is structured into six chapters. The first of these corresponds to the current Chapter 1 ("Introduction"), in which the problem to be solved is described, the working hypothesis is formulated, the different objectives are detailed, and the research methodology followed for the completion of this Doctoral Thesis is described.

Chapter 2 presents a review of the current state of the art in occupational safety in Section 2.2, IoT applied to PPE, Wearables and Smart Textiles in Section 2.3, AI integration in Section 2.4, platforms and architectures for prevention in Section 2.5 and finally some conclusions in Section 2.6, describing the different innovations in each of these areas.

Chapter 3 describes the contributions resulting from the research conducted as part of this Doctoral Thesis. It details and describes the system for different usage scenarios and with different PPE devices. It also compares different Artificial Intelligence models for the analysis of real-time data, as well as a recognition of human activity combined with other unsupervised learning algorithms to detect anomalies. Thanks to the knowledge acquired, a modular Edge Computing platform is presented, which makes it possible to adapt to the environment and connect a multitude of devices with different communication technologies.

Chapter 4 ("Contributions") explains the integral Edge-AIoT system and includes the articles that are part of this Doctoral Thesis by compendium of publications. Each one accompanied by its corresponding introduction, set of objectives, description of the research methodology used in each one, as well as the conclusions of the results obtained in each one of those publications.

Chapter 5 ("Evidence and results") presents the results of the research carried out for this Doctoral Thesis, which is evidenced by the set of publications in scientific journals, conferences, congresses, book chapters and international workshops, as well as the research projects in which it has participated. It also details the stays carried out at international research organization over the course of the research summarized in this Doctoral Thesis.

Finally, Chapter 6 details the most principal conclusions that have been drawn from the conducted research and outlines its most significant contributions. In addition, future lines of research are defined for further development. At the end, a complete list is provided of all the bibliographic sources that have been used as reference and are cited within this Doctoral Thesis, which have served to support the presented statements and concepts.

Capítulo 2

Estado del Arte



VNiVERSiDAD
D SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

Estado del Arte

La seguridad y salud en el entorno de trabajo es uno de los retos que generan mayor preocupación dentro del ámbito empresarial y de forma especial, en el sector industrial. En este sentido, gracias a diferentes estudios se ha determinado que la incorporación de tecnología en diferentes trabajos industriales puede reducir significativamente el número de accidentes e incidencias. Actualmente, las empresas del sector industrial están centrándose sus esfuerzos en incorporar avances en el modelo de la Industria 4.0, para seguir compitiendo en un mercado cada vez más tecnificado. Estos avances, además de la productividad, tienen un notable impacto en el entorno laboral de los trabajadores y en las medidas adoptadas para mantener un espacio de trabajo saludable. Existen ejemplos de proyectos que utilizan tecnologías como Realidad Aumentada (Augmented Reality – AR) la formación industrial y el mantenimiento de equipos (Tatić & Tešić, 2017), dispositivos y sensores basados en el Internet de las Cosas (Internet of Things - IoT) para el monitoreo del personal y el entorno (Fathallah, Lecuire, Rondeau, & Le Calvé, 2015; Gnoni, Bragatto, Milazzo, & Setola, 2020; Pavón et al., 2018; Podgorski, Majchrzycka, Dabrowska, Gralewicz, & Okrasa, 2017), uso de aprendizaje automático utilizando técnicas Machine Learning (Matías, Rivas, Martín, & Taboada, 2008; Sarkar & Maiti, 2020) o plataformas de análisis Big Data para ingerir los datos procedentes de la industria (Badri, Boudreau-Trudel, & Souissi, 2018; Tarrahi & Shadravan, 2016). Sin embargo, las plataformas propuestas son demasiado generalistas y las soluciones diseñadas son demasiado específicas o poco adaptables a los problemas encontrados dentro de la industria. En este Capítulo se presenta una revisión del estado del arte en los enfoques existentes de innovación en la Prevención de Riesgos Laborales (Occupational Risk Prevention ORP) (Eeckelaert et al., 2012), basándonos en la innovación en nuevos materiales a incorporar en los EPIs, para la creación de EPIs inteligentes y la integración de diferentes tecnologías en las estrategias de PRL, para así ofrecer a los trabajadores de

elevadas garantías de protección frente a accidentes, pero lo que es aún más importante, ofrecer recursos para el soporte mediante una plataforma centralizada para, en un alto porcentaje de casos, evitar esas situaciones de riesgo y accidentes.

Así, en el resto de este Capítulo se describen progresivamente las diferentes tecnologías que permiten una protección inteligente de los trabajadores en la industria. Entre ellas, se va a analizar el estado actual de la técnica en Prevención de Riesgos Laborales (PRL) u Occupational Risk Prevention (ORP), Internet de las Cosas (Internet of Things - IoT), Wearables y Textiles Inteligentes (Smart Textiles), modelos de Inteligencia Artificial (IA), arquitecturas de procesamiento Edge y Cloud Computing, así como mecanismos inteligentes para la gestión de las incidencias utilizando plataformas software de ingestión y visualización de la información. La Sección 2.1 expone un primer acercamiento a las tecnologías bajo estudio y analiza las revisiones existentes dirigidas al ámbito de la Prevención de Riesgos Laborales (PRL) utilizando Internet de las Cosas (Internet of Things - IoT), Wearables, Textiles Inteligentes (Smart Textiles), Machine Learning, arquitecturas Edge y Cloud Computing, así como plataformas dotadas de cierta inteligencia. La Sección 2.2, por su parte, analiza diferentes trabajos y normativas en el área de la PRL que tienen cierta relevancia en este ámbito y que han servido de apoyo para el trabajo presentado. La Sección 2.3 describe la situación actual e investigaciones desarrolladas en el ámbito del IoT, la tecnología Wearable y de los Textiles Electrónicos, EPIs Inteligentes (Smart PPEs). La Sección 2.4 narra todos aquellos trabajos de especial interés en el área de la Inteligencia Artificial y la aplicación de modelos Machine Learning, y describe las técnicas de aprendizaje basadas en Inteligencia Artificial, para realizar un procesamiento de los datos y gestionar de forma efectiva las alarmas o anomalías detectadas. La Sección 2.5 presenta el uso la Computación en Borde (Edge Computing) y Computación en la Nube (Cloud Computing) en el entorno industrial, y además, describe diferentes arquitecturas y plataformas que pueden asemejarse a la soluciones que se proponen en esta Tesis Doctoral. Por último, en la Sección 2.6, se exponen las principales conclusiones obtenidas después de este análisis.

2.1. Introducción

Según los últimos datos publicados por el Instituto Nacional de Estadística en 2019 basados en la información de Seguridad Social Española, se han producido un total de

1.359.548 accidentes laborales, entre los cuales, el número de accidentes laborales con baja fue de 635.227 sobre un total de 19,75 millones de trabajadores. El número de accidentes sin baja fue de 724.321, lo que supone un 53 % del total y entre los accidentes con baja, 3542 fueron incidentes graves, y 489 fueron accidentes mortales (Ruiz Pérez, 2019). Según el tipo de profesión, existe una mayor exposición a realización de tareas de alto riesgo, donde existe la posibilidad de que se produzcan accidentes mortales. Existen factores que desencadenan el malestar de los trabajadores como son la fatiga y el estrés, y además si estos se encuentran de forma continuada expuestos a vibraciones, la exposición al sol, temperatura extremas, gases o ruido, también introducen riesgo en el entorno laboral (Pavón, Sigcha, López, & De Arcas, 2017).

La seguridad laboral ha mejorado en las últimas décadas, gracias a la exigencia de leyes que amparan los derechos de los trabajadores, la mejora de las condiciones laborales y la fuerte apuesta por la formación en PRL como herramienta fundamental para reducir la siniestralidad. A estos factores, hay que sumar un cuarto, transversal a todos ellos y que se ha erigido como habilitador fundamental para el apoyo y soporte de todos ellos: la tecnología.

En los últimos años, se han diseñado numerosos sistemas basados en las Tecnologías de la Información (TICs) o Information and Communication Technologies (ICTs), con los que se busca reducir estos accidentes, sin embargo, su uso todavía no está muy extendido. Siguiendo este esquema, las actuales propuestas tratan de revolucionar la manera tradicional en la cual la industria ha trabajado para la mejora de estos aspectos, basándose sobre todo en la innovación en nuevos materiales a incorporar en los EPIs, la integración de la gestión de PRL con sistemas de gestión empresarial y su inclusión en certificaciones de procesos. Para ello, la apuesta que formula la presente Tesis Doctoral es una revolución estructural, entendiendo la tecnología, la formación y la gestión de procesos como un todo, y proporcionando una herramienta para el trabajador (EPI Inteligente), que le ofrezca unas elevadas garantías de protección frente a accidentes, pero lo que es aún más importante, que le ofrezca recursos para, en un alto porcentaje de casos, evitar esas situaciones de riesgo.

En este sentido, basándose en la información disponible (EPI Inteligente, Sensores, directrices de PRL, procedimientos...). Se entiende EPI según el Real Decreto 773/1997 por .^Equipo de Protección Individual cualquier equipo destinado a ser llevado o sujetado

por el trabajador para que lo proteja de uno o varios riesgos que puedan amenazar su seguridad o su salud, así como cualquier complemento o accesorio destinado a tal fin. Los EPI deben ofrecer una protección eficaz frente a los riesgos y deben estar fabricados según las normas europeas o normas EN correspondientes y cumplir con el R.D. 1407/1992 de comercialización de los EPI. Los equipos de protección individual deberán utilizarse cuando existan riesgos para la seguridad o salud de los trabajadores que no hayan podido evitarse o limitarse suficientemente por medios técnicos de protección colectiva o mediante medidas, métodos o procedimientos de organización del trabajo (Vida et al., 2006; Zúñiga, 2003).

Los consumidores del siglo XXI reclaman productos con altas prestaciones y funcionalidad. En el futuro próximo, los productos textiles se transformarán en sistemas sensibles, multifuncionales y adaptables. Investigaciones en diferentes campos trabajan en convertir los tejidos tradicionales en Textiles Inteligentes (Smart Textiles / Intelligent textiles) que se tratan de estructuras textiles que puede “sentir” e incluso reaccionar ante diferentes estímulos del entorno” (Tao & et al., 2015). Los estímulos ante los que puede reaccionar pueden ser físicos, mecánicos, eléctricos, térmicos y químicos, etc. (presión, temperatura, luz, presión, humedad, tiempo...). De una forma simple el textil siente y reacciona automáticamente sin el control de ninguna unidad y de una forma más compleja el Smart Textil siente, reacciona y activa una función específica a través de la unidad de proceso. En las dos últimas décadas, los mayores esfuerzos están enfocados en desarrollar E-textiles, es decir a la integración de textiles y electrónica. Los E-textiles, conocidos como textiles electrónicos, están recogidos dentro de la tecnología denominada wearable (que se puede utilizar como ropa) y, en general, a los textiles inteligentes (Smart Textiles). En ellos las telas llevan internamente los componentes electrónicos e interconexiones, que incorporan la capacidad de medición (externa o biométrica); de comunicación mediante la interconexión interna y de transmisión información. E incluso en determinados casos la información puede procesarse informáticamente proporcionando una funcionalidad adicional y la integración conveniente en la vida cotidiana de sus usuarios. Las prendas inteligentes o ropa inteligente (Smart Garments), son prendas de vestir constituidas, al menos en parte, por fibras o tejidos denominados inteligentes que proporcionan mayor funcionalidad a través de la detección de determinadas señales, el procesamiento de éstas e incluso su actuación en un determinado sentido. Son capaces de percibir

estímulos del entorno, reaccionar y adaptarse a éstos mediante la integración de la funcionalidad en la estructura textil. Los estímulos son respuesta a señales físicas, eléctricas, térmicas, químicas, magnéticas, mecánicas o de otro origen (Tao & et al., 2015). La tecnología utilizada tiene algunas de las siguientes características: flexible, estirable y con propiedades mecánicas, por ejemplo, por la utilización de transductores electro-mecánico. En cuanto a su mantenimiento debe ser de fácil limpieza e incluso lavable. Además, los e-textiles pueden ser portables o integrables en la ropa, pero también pueden tener aplicaciones en elementos del hogar (cortinas, muebles, etc.) y en otras (tapicerías de automóviles, trenes, aviones...). A pesar del esfuerzo en desarrollo de diferentes proyectos solo unos pocos productos están en el mercado.

Los llamados Ordenadores Corporales (Wearable Computers) fueron inventados por el profesor de la Universidad de Toronto Steve Mann, a finales de 1970, (Mann, 2012) y se definen como un dispositivo electrónico portátil diseñado para interactuar con la persona que lo porta y está adherido al cuerpo, pudiendo colocarse debajo de la vestimenta, en ella o por encima de ella. En ellos existe una interacción constante entre el dispositivo y el usuario, reaccionando automáticamente a funciones que el usuario realiza voluntariamente (por ejemplo, un comando de voz) o involuntariamente (por ejemplo, cambio en la frecuencia cardíaca), estando siempre accesibles y con capacidad multitarea. El desarrollo de dispositivos corporales con estas funciones se ha intensificado de forma notable con la miniaturización de los componentes electrónicos, pasando a diseños completamente integrados. Los actuales Gadgets wearables son aquellos dispositivos que se alojan en alguna parte del cuerpo del usuario, como pulseras de fitness u ordenadores miniaturizados que se pueden conectar a ciertas partes del cuerpo, tales como la muñeca o la cabeza, e incluso llevarse en unas gafas. La interpretación automática de los datos de los sensores relacionados con la actividad, el estado del usuario, el entorno y la ubicación, se resume bajo el término conocimiento del entorno o contexto de aplicación. Los textiles y prendas inteligentes pueden aportar datos sustanciales para su interpretación y adaptación del sistema al contexto (G. Chen & Kotz, 2000).

Las Redes Inalámbricas de Sensores (WSN –Wireless Sensor Networks) son cada vez más empleadas en múltiples y muy diversos ámbitos: aplicaciones industriales, entornos domóticos, aplicaciones médicas, vigilancia o incluso en el sector agropecuario (Qian & Wang, 2013; Zhang & Zhang, 2012). Además, las Redes Inalámbricas de Sensores comprenden una tecnología clave a la hora de obtener información acerca del contexto

en aplicaciones basadas en el paradigma de la Inteligencia Ambiental, que se fundamenta en máximas como la computación ubicua y el establecimiento de interacciones entre hombre y tecnología centradas en el usuario. Existen diversas tecnologías inalámbricas mediante las cuales es posible implementar Redes Inalámbricas de Sensores. Algunos de estos estándares permiten, de hecho, la implementación de redes cableadas de sensores o soluciones híbridas. Sin embargo, en los protocolos de formación de la red, la topología de la misma, los métodos de transmisión de información o incluso las frecuencias o codificación de datos empleadas, pueden ser totalmente diferentes entre sí, haciendo que estos estándares no sólo sean incompatibles entre sí, sino que además sean conceptualmente muy diferentes. En función de la aplicación en las que estén implementadas este tipo de redes, podemos contar con sensores de tipo industrial, domótico o ambiental, de cara a medir magnitudes físicas tales como la temperatura ambiental, la humedad o determinados niveles de humo o gases; sensores biomédicos, que permiten tomar medidas de magnitudes de interés médico como la temperatura de un paciente, su ritmo cardíaco o su actividad muscular; sensores biológicos o biosensores, que pueden consistir en enzimas o cadenas de aminoácidos, entre otros, y que pueden ser empleados para mediciones de, por ejemplo, glucemia o niveles de pesticidas en el agua; o sensores biométricos, enfocados en el reconocimiento de patrones morfológicos humanos tales como las huellas dactilares, la voz o el iris ocular y con una amplia aplicación en sistemas de seguridad. La diversidad en la naturaleza de los sensores y actuadores empleados en estas redes tiene, además, distintas implicaciones en la forma de recoger la información proporcionada por los mismos. Mientras que la información de los sensores biomédicos puede ser de vital importancia y debe ser transmitida de forma continua e ininterrumpida, los datos de ciertos sensores domóticos pueden ser transmitidos a una baja frecuencia sin importar si algunos de ellos son perdidos por el camino. Otros datos, como los proporcionados por los sensores biométricos, pueden requerir, por privacidad y seguridad, la transmisión cifrada de los mismos.

La Inteligencia Ambiental (Ambiental Intelligence - AmI) se define como aquel modelo de interacción donde las personas están rodeadas de un entorno inteligente, que actúa como elemento consciente la presencia del humano, siendo sensible al contexto y con la capacidad de adaptarse a las necesidades que aparezcan. Para lograr este tipo de interacción se utiliza tecnología embebida, con la finalidad de facilitar sus actividades de una forma no invasiva y transparente. La Inteligencia Ambiental puede verse como el

futuro en la evolución de la sociedad de información, donde los dispositivos e interfaces inteligentes están mimetizadas en la vida cotidiana. Para ello se requiere de entornos que integren la capacidad de procesamiento, computación y comunicación de una forma inteligente, al servicio de las personas. Esta interacción entre sistema y humano, debe buscar ser simple, natural y sin un esfuerzo de aprendizaje elevado para el usuario. Se prevé que en el futuro, la incursión de la tecnología y dispositivos cada vez será mayor, por ello, la solución será la creación de sistemas cada vez más intuitivos e inteligentes, con la capacidad de reconocer y responder las necesidades de los individuos, de una forma automática. Las personas serán por ello el centro del desarrollo en la creación de entornos que integren como forma de interactuar la Inteligencia Ambiental, y con ella una nueva forma de interactuar entre tecnología y las personas. En este contexto, la tecnología debe adaptarse a los usuarios y al contexto o entorno de acción, con la integración y despliegue de dispositivos que den soporte a los usuarios de forma interactiva y autónoma en la realización de tareas diarias. Los sistemas apoyados en la AmI buscan mejorar la calidad de vida en los usuarios, gracias al desarrollo conjunto de modelos y técnicas, donde la mejora en la interacción entre los usuarios y el entorno sea el fruto resultante (Salih & Abraham, 2013; Sharma, Kumar, & Bhardawaj, 2014).

En la actualidad existen muchos ejemplos de máquinas virtuales que se han construido gracias a la Inteligencia Artificial, con capacidad para aprender patrones de respuesta, mediante la supervisión parcial o total de un actor externo y que pueden extraer una respuesta particular a un problema dado, generalizándolo para casos a los que no se han enfrentado con anterioridad. Esta forma de aprendizaje automático se usa de manera amplia en tareas para la clasificación y regresión de datos (Jackowski, Jankowski, Quintián, Corchado, & Woźniak, 2016). De la misma manera que en este tipo de tareas, el reconocimiento de patrones juega un papel muy importante, ya que se encarga de la descripción y clasificación de objetos, por extensión, también es fundamental en el reconocimiento de escenarios, en los que permiten aplicar respuestas previamente almacenadas e incluso el desarrollo de nuevas resoluciones, provocadas por la aparición de determinados factores desencadenantes. Esta operativa responde a la analogía de que objetos o escenarios similares, permiten pensar que tendrán similitudes en el espacio de sus características o reaccionarán de manera similar frente a determinados respuestas (S. Sánchez, Rodríguez, Prieta, Paz, & Bajo, 2015). Este aprendizaje automático, a su vez resulta fundamental para desarrollar los mecanismos que intervienen en la toma de

decisiones que, en esencia, no es más que un automatismo que realiza una elección, sobre varias opciones o acciones para la resolución de diversas situaciones (Fernández Canelas, Martín Martín, Corchado Rodríguez, & et al., 2014). Este proceso, que hasta hace no mucho tiempo se realizaba de forma manual, sobre unas series de datos, en la actualidad se ha asociado a otras tecnologías innovadoras (Big Data, captura masiva de datos, incremento de la capacidad de computación...) para revolucionar el mercado de la información. Basado en los sistemas predictivos y con la incorporación de algoritmos mezcla de expertos y Razonamiento basado en casos (Case-Based Reasoning - CBR), se pueden desarrollar sistemas que actúen a un doble nivel: identificando las mejores respuestas para cada caso concreto y realizando una continua tarea de evaluación de sus respuestas, basada en el Aprendizaje profundo (Deep Learning - DL), que permita mejorar la precisión de las propuestas que realiza. Estos modelos, no solo explotan la disponibilidad de los datos y la capacidad analítica que se puede desplegar gracias a ellos, si no que incorpora una componente de IA que permite al sistema evolucionar de forma autónoma, permitiendo dar el salto al Smart Data y mejorando las soluciones que es capaz de sugerir. Este aspecto, unido a la interactividad de los Dispositivo de interfaz humana (Human Interface Device - HID) que se incorporan en el Smart EPI, prometen revolucionar el sistema de los asistentes virtuales en entornos de trabajo y su uso para acciones formativas.

En la industria es necesario recopilar datos de diversas fuentes de forma fiable (Dong & Srivastava, 2013) y unificada, transformándolos para poder obtener información que facilite la escalabilidad de los procesos, reduciendo tiempos y costes de desarrollo (Bokor, 2012). Esto supone que, por norma general, en los entornos industriales, existan muchos medios y posibilidades para la captura de datos. Para ello, ha de prestarse atención a la seguridad (Karr, Lin, Sanil, & Reiter, 2009) y calidad (Lenzerini, 2002) de la información que se maneja, que ha de reflejarse en un plan de acción para la integración de datos de fuentes heterogéneas, pasando por la evaluación del valor añadido de la fuente y la ventaja competitiva que aporta, buscando que redunde en la agilidad de las tareas para un manejo eficiente de los procesos de cambio. Por su parte, las plataformas que utilizan Edge Computing facilitan el uso eficiente de sistemas de análisis que puedan funcionar tanto con conexión a internet como sin ella. Así, el análisis facilita el mejor funcionamiento de dispositivos EPIs en las tareas de detección, implicando un aumento significativo de la seguridad, la eficiencia energética y la velocidad de respuesta. La

capacidad para percibir los cambios en el entorno y reaccionar ante ellos, hace de esta metodología un enfoque ideal para obtener datos del entorno y responder a estos cambios con acciones adecuadas. Características como la extensibilidad y la flexibilidad permiten añadir nuevas funcionalidades o incluir otros algoritmos y sensores (San Románn Lana & et al., 2019). Para poder integrar esta información en una herramienta inteligente que los relacione, necesitan ser caracterizados y contemplados desde la fase de diseño, permitiendo desarrollar metodologías ad-hoc que permitan explotar la información de forma nativa y extraer todo su valor. Es por ello, que la incorporación de capas que aporten tecnología sobre la infraestructura existente (propia de sistemas de gestión para la PRL), apenas tiene impacto en la mejora de los indicadores de siniestralidad, ya que, en su mayoría, lo único que hacen es incorporar un registro de los EPIs y las tareas que se realizan sobre ellos (uso y mantenimiento).

2.2. Seguridad en el trabajo

La seguridad del trabajo pretende detectar y corregir los riesgos de accidentes de trabajo, mediante técnicas de seguridad, previniendo aquellos factores causantes de los accidentes con los objetivos generales de: suprimir el riesgo y proteger al operario. Por ello es necesario realizar un estudio de las diferentes normativas y manuales de Prevención de Riesgos Laborales ”PRL” (Vida et al., 2006) a partir del cual se puedan conocer los riesgos que se pueden captar gracias a su compatibilidad con las herramientas/dispositivos. Para ello, se debe identificar las situaciones que presentan una mayor incidencia en diferentes escenarios, agrupadas por actividad/sector. Este estudio permite construir modelos para la detección de riesgos emergentes y crear ontologías para la asociación de acciones y riesgos. Por ejemplo, las estadísticas de caídas muestran que las consecuencias más graves podrían solucionarse con una atención temprana, ya que a veces la lesión o contusión provoca una pérdida de conciencia o la imposibilidad de pedir ayuda. Así, un sistema de alerta automática podría suponer una mejora significativa de la seguridad de los trabajadores. Existe una relación entre el tiempo que el trabajador pasa tumbado en el suelo y la gravedad de la caída. Además, el miedo a las caídas conlleva una importante disminución de la calidad de vida de las personas a medida que envejecen, reduciendo sus salidas, su vida social y su independencia. En los trabajadores de edad avanzada el

miedo puede aumentar el riesgo de caídas (Noury, Rumeau, Bourke, ÓLaighin, & Lundy, 2008).

Entendemos como peligro aquellas situaciones que pueden derivar en un daño para una persona y cuando la persona se encuentra en su campo de acción se convierte en un riesgo. Desde el punto de vista laboral son múltiples y de muy diverso origen, y surgen generalmente como consecuencia del estado en que se encuentran los agentes materiales, instalaciones, superficies de tránsito, equipamientos, etc. La Ley de Prevención de Riesgos Laborales (L.P.R.L.) obliga a una acción preventiva por parte del empresario tendente a la eliminación de los riesgos, y en caso de imposibilidad a que se realice una evaluación de los mismos (Vida et al., 2006).

Para el caso del entorno de Trabajo y PRL encontramos las siguientes normativas de aplicación: Real Decreto 485/1997 De 14 de abril, sobre disposiciones mínimas en materia de señalización de seguridad y salud en el trabajo. Real Decreto 486/1997 De 14 de abril, por el que se establecen las disposiciones mínimas de seguridad y salud en los lugares de trabajo. Ley 31/1995 De 8 de noviembre, de prevención de Riesgos Laborales. Real Decreto 39/1997 De 17 de enero, por el que se aprueba el Reglamento de los Servicios de Prevención.

En el caso de España se deben considerar las siguientes normativas aplicables para el caso de los EPIs y Equipos de Trabajo: Real Decreto 1407/1992 De 20 de noviembre, por el que se regula las condiciones para la comercialización y libre circulación intracomunitaria de los equipos de protección individual. Real Decreto 773/1997 De 30 de mayo, sobre disposiciones mínimas de seguridad y salud relativas a la utilización por los trabajadores de equipos de protección individual. Real Decreto 1215/1997 De 18 de julio, por el que se establecen las disposiciones mínimas de seguridad y salud para la utilización por los trabajadores de los equipos de trabajo. Los EPI están diseñados para proteger a los trabajadores de las lesiones y enfermedades en el espacio de trabajo resultantes del contacto con riesgos químicos, físicos, eléctricos, mecánicos radiológicos y otros. Se ha investigado sobre los equipos y sistemas auxiliares de detección, aviso e identificación de peligros, que pueden integrarse en el sistema, garantizando que los trabajadores cumplan los requisitos de seguridad (Coria, Castellanos-Garzón, & Corchado, 2014; Nihan, 2013; Oliveira, Neves, & Novais, 2012; D. I. Tapia, Fraile, Rodríguez, Alonso, & Corchado, 2013; Xian, Tarrío Alonso, Bernardos Barbolla, Metola Moreno, & Casar Corredera,

2012). Algunos de los EPI que podemos utilizar como sugiere el libro (Zúñiga, 2003) son cascos de protección, ropa de protección, protectores auditivos, protectores de las vías respiratorias, guantes de protección, protectores oculares y faciales, zapatos y botas de seguridad, protectores anticaída y chalecos salvavidas.

Los equipos de protección son de uso obligatorio en los casos en que la seguridad del trabajador está en riesgo. Sin embargo, no siempre es posible detectar a tiempo las situaciones de peligro, lo que hace que se produzcan accidentes. Este tipo de sucesos ponen en entredicho la seguridad y la salud del trabajador; y con ello la confianza del trabajador en la empresa para la que trabaja disminuye (Bensel & Santee, 2006; Champoux & Brun, 2003; Granerud, 2011; Stafford & Hazle, 2006). Para una prevención eficaz de las lesiones o de los accidentes mortales en el entorno laboral, la integración de los componentes electrónicos es crucial dada su capacidad de detección precoz de los riesgos. Las investigaciones de (Henley & Kumamoto, 1985), propusieron un enfoque cuantitativo para el diseño óptimo de los sistemas de seguridad, que se centraba en los vínculos de información humana e informática, los sensores y los sistemas de control. En 2003, la investigación de (Han & Song, 2003) sobre la monitorización de la condición (Condition Monitoring - CM) incluyó una revisión de los métodos de CM más conocidos, así como el estado de la investigación sobre el generador, el transformador y el motor de riesgos, respectivamente. (Glendon & Litherland, 2001), determinaron la estructura de un clima de seguridad (Safety Climate Questionnaire – SCQ) dentro de una organización de construcción de carreteras. También investigaron la relación entre el clima de seguridad y el rendimiento de la seguridad. En marzo de 2011, el AIoT o Internet inteligente de las cosas para el mantenimiento de equipos (Intelligent Internet of Things for Equipment Maintenance - IITEM) fue presentado por (Xiaoli, Yunbo, & Guoxin, 2011). También, encontramos trabajos de tratamiento de información estática y dinámica de los equipos electrónicos y mecánicos, recopilada por todo tipo de sensores, considerando además diferentes estándares de transmisión IoT (Casado-Vara, Chamoso, De la Prieta, Prieto, & Corchado, 2019; Casado-Vara, González-Briones, Prieto, & Corchado, 2018).

En cuanto al ámbito concreto de la detección de caídas, (Hawley-Hague, Boulton, Hall, Pfeiffer, & Todd, 2014) realizaron una revisión sistemática de los estudios sobre la percepción que tienen las personas de la tecnología para la prevención o detección de estas. Estos autores concluyen que hay una serie de factores intrínsecos y extrínsecos

que motivan a las personas a utilizar esas tecnologías y adoptarlas de forma permanente. Entre los factores intrínsecos destacan 1) El control del usuario para anular las falsas alarmas o desactivar el sistema en determinados momentos. 2) La independencia adquirida con el sistema para moverse sin miedo. 3) La autopercepción del usuario sobre su riesgo de caída. Además, (Abdelhamid & Everett, 2000) presentaron un modelo de seguimiento de las causas fundamentales de los accidentes (Accident Root Causes Tracing Model - ARCTM), adaptado a las necesidades del sector de la construcción. (Cambreia, Saurin, & Formoso, 2010) definió las directrices para identificar, analizar y difundir la información sobre los cuasi accidentes en las obras de construcción. (Teizer, Cheng, & Fang, 2013), presentaron tres estudios de caso que empleaban métodos para registrar datos y visualizar información sobre las actividades de construcción en (1) una obra de construcción virtual simulada, (2) un entorno de construcción exterior y (3) un entorno de formación de trabajadores. Además, la teoría de los sistemas ha sido incorporada a la teoría del dominó de (Chi & Han, 2013) para explorar las interrelaciones entre los riesgos y romper la cadena de causalidad de los accidentes. En abril de 2008, las razones por las que los trabajadores de la construcción adoptan comportamientos inseguros fueron analizadas en la investigación empírica de (Choudhry & Fang, 2008). Además, (Fitton et al., 2008) aplicó la tecnología de realidad aumentada (Aumented Reality -AR) con tecnologías de detección y comunicación que pueden medir el uso de los dispositivos, con el fin de permitir nuevos modelos de pago por uso para el alquiler de equipos. Esto puede lograrse mediante la incorporación de sensores para el control de los parámetros ambientales y la captación del movimiento.

2.3. IoT aplicado a EPIs, Wearables y Textiles inteligentes

La historia de los primeros PPE inteligentes vienen de la década de los noventa con investigaciones en el campo militar, aeroespacial y de la tecnología vestible (wearable). La posibilidad de integrar electrónica en el cuerpo gracias a productos wearables o textiles inteligentes se tomó como un foco de investigación y el desarrollo actual de la tecnología hace que empiecen a salir los primeros productos comerciales. En campos como ropa para profesionales como bomberos, militares o trabajadores, la tendencia es sacar productos adaptados a sus necesidades. Además por otro lado gracias a

dispositivos como los SmartWatch podemos encontrar productos adaptados a varios sectores, entornos y públicos.

En la última década, los dispositivos vestibles han captado la atención de las industrias y de la comunidad académica. Este interés se ha manifestado en la creciente tendencia de las organizaciones a investigar y desarrollar estos productos. Dentro de los textiles inteligentes aplicados a la protección personal, el rango de aplicaciones que pueden cubrir es muy amplio. Estos tienen entre sus capacidades la posibilidad de interactuar con diferentes parámetros, con la posibilidad de captar un estímulo y transformarlo en una señal como temperatura, humedad, campo electromagnético, radiación, movimientos, fuerzas, actividad biológica, etc.

A partir de investigaciones precursoras sobre cómo integrar líneas conductoras y circuitos en los textiles, realizadas a fines de la década de 1990, los pasos posteriores dieron lugar a una combinación más funcional entre sensores, actuadores, interfaces y circuitos textiles. Los textiles de hoy en día tienen aplicaciones en una gran variedad de actividades, en campos como el de la salud, deporte, moda, decoración, mobiliario, espacial, militar, ropa laboral, entretenimiento, etc. Mediante la tecnología se busca dar valor añadido a los tejidos, hilos, fibras y estructuras, buscando la innovación y la transformación en tejidos con funcionalidad dinámica. En los últimos años, el campo de los textiles inteligentes y las prendas inteligentes ha explorado un desarrollo en nuevos campos de aplicación centrados en la supervisión e interacción basadas en sensores. Dentro del monitoreo y supervisión fisiológico y físico basado en sensores se engloba la adquisición de signos vitales en la vigilancia médica, sistemas de seguridad para prendas técnicas o profesionales y estimación de la actividad física en deportes. Una característica esencial para cualquier aplicación de monitoreo es la calidad de los datos proporcionados. Se pretende por tanto maximizar la resistencia de los dispositivos y mejorar la calidad de las mediciones, al mismo tiempo que conservan las propiedades mecánicas de los tejidos. La interacción implícita en los tejidos inteligentes puede aprovechar el potencial de combinación de movimientos del usuario con gestos corporales, bien sea de dedos, brazos, piernas, etc. En un sentido amplio, la combinación de la informática con la ropa se refiere a dispositivos que soportan la entrada/salida de datos y ello aporta una determinada funcionalidad a la ropa.

La historia de la informática portátil o wearable se remonta mucho tiempo antes

del desarrollo real de los ordenadores. Así, los materiales básicos necesarios para la fabricación de textiles electrónicos, hilos y tejidos conductores han existido desde hace más de mil años. En 1961, los matemáticos Edward O. Thorp, y Claude Shannon (Thorp, 1998) construyeron el primer ordenador portátil wearable, un dispositivo para hacer trampas en el juego de la ruleta calculando probabilidades, que podía ocultarse en un zapato, del tamaño de una cajetilla de cigarros. En 1968, Ivan Sutherland creó una pantalla que utilizaba pequeñas pantallas Tubo de rayos catódicos (Cathode Ray Tube - CRT) que colocadas delante de los ojos del usuario proyectaban imágenes e información y que de esta forma el usuario pudo ver tanto el entorno físico como el virtual (Sutherland, 1968). En 1985, el inventor Harry Wainwright creó la primera sudadera animada, esta contenía fibra óptica, cables y un microprocesador para controlar los colores de forma individual dentro de la animación (Syduzzaman, Patwary, Farhana, & Ahmed, 2015). A principios de los años noventa, los beneficios de los textiles inteligentes se hicieron evidentes, fuertemente influenciados por las investigaciones en el campo militar y la tecnología vestible (wearable) en general.

La apariencia discreta de la ropa inteligente y la posibilidad de interactuar con microprocesadores, ha provocado que se puedan realizar medidas físicas y del estado fisiológico del usuario, líneas en las que se centran muchos proyectos de investigación. A mediados de la década de 1990, un equipo de investigadores del MIT dirigido por Steve Mann, Thad Starner y Sandy Pentland comenzó a desarrollar lo que denominó “wearable computing” que consiste en añadir al cuerpo un equipo electrónico tradicional (Starner et al., 1995). En respuesta a los retos técnicos, otro grupo en el MIT compuesto por Maggie Orth y Rehmi Post, comenzó a explorar cómo dichos dispositivos podrían integrarse de forma más funcional en la ropa y otros sustratos blandos, desarrollando por ejemplo el bordado de circuitos electrónicos o la integración de electrónica digital con tejidos conductores (Post & Orth, 1997; Post, Orth, Cooper, & Smith, 2001; Post, Orth, Russo, & Gershenfeld, 2000). O las primeras chaquetas ECG bio-physical (Syduzzaman et al., 2015).

Una de las primeras computadoras portátiles basadas en textiles fue la camisa sensora (Farringdon, Moore, Tilbury, Church, & Biemond, 1999), que medida la postura del usuario de la parte superior del cuerpo utilizando en total once galgas extensiométricas colocados sobre las articulaciones. (Harms, Amft, Roggen, & Tröster, 2008) mostraron cómo utilizando sensores de movimiento Unidad de medición inercial

(Inertial Mesasurement Unit – IMU) se podía analizar también postura. (Mattmann, Amft, Harms, Troster, & Clemens, 2007) analizaron un sensor de hilo que está casi libre de histéresis mientras se mide la elongación a lo largo de partes del cuerpo, por ejemplo, la espalda. (Shyr, Shie, Jiang, & Li, 2014) consiguieron relacionar sensores de deformación con el ángulo de flexión de extremidades y (Cho, Jeong, Paik, Kwun, & Sung, 2011) compararon diferentes tejidos conductores y su rendimiento para medir ángulos de unión .

De la integración de sensores se consigue prevenir lesiones de deportistas, alcanzar un rango óptimo de trabajo y medir acciones sin interferir con el movimiento del atleta. Además de las actividades implícitas de detección y análisis, la prenda también se puede utilizar para la entrada explícita, por ejemplo, a través de la entrada táctil (Schneegass & Voit, 2016). Uno de los proyectos pioneros fue el que desarrolló el “Tech Wearable Motherboard”, prenda que integraba sensores y capacidad de comunicación, con el propósito de la monitorización del estado de salud en tiempo real de los militares que participan en acciones bélicas (Gopalsamy, Park, Rajamanickam, & Jayaraman, 1999). En el proyecto multinacional “MyHeart” europeo, se desarrolló y evaluó ropa interior para la prevención de enfermedades cardiovasculares, teniendo capacidad de realizar un electrocardiograma (Electrocardiogram - ECG) y de medir la respiración, la frecuencia cardiaca y otros parámetros (Schneegass et al., 2015). La camisa de SimpleSkin combina la detección fisiológica y física (Amft, Habetha, & Van Langenhove, 2007). Choi y Jiang presentaron un sistema destinado a la medición cardiorrespiratoria para controlar la condición del sueño (Schneegass et al., 2015).

Los principios generales de construcción de tejidos y prendas inteligentes se amplían continuamente. Dunne et al. proporcionaron una visión general sobre las estrategias de integración de los textiles y sus anexos (Dunne, Gioberto, & Simon, 2015). Desafío clave en cuanto a la interpretación de sensores de prendas de vestir es su adaptación variable dependiendo del movimiento y la forma del cuerpo. Harms et al. dieron una visión general de un marco de predicción que se ocupan de errores debido a la adaptación suelta en la orientación, contacto con la piel, y la detección de la tensión (Harms, Amft, & Tröster, 2012).

Entre las significativas investigaciones que han servido como referencia para este trabajo por un lado cabe destacar el desarrollo de nuevos sensores ofrece grandes mejoras en

este tipo de aplicaciones (Fishta et al., s.f.; Podgorski et al., 2017; Scheinder, 2014) y por otra parte la utilización de materiales inteligentes embebidos en el propio PPE como por ejemplo mediante la utilización de microcápsulas PCM de cambio de fase que reaccionan con el cambio brusco de temperatura (Mondal, 2008) o la posibilidad de generar electricidad a través del movimiento (Rocha, Goncalves, Rocha, Silva, & Lanceros-Mendez, 2009).

Algunos trabajos se encuentran más expuestos por las condiciones del entorno y la naturaleza de los mismos, por lo que en función de estos se debe diseñar una solución adaptada, válida para las diferentes problemáticas que podemos encontrarnos (Scott, 2005). Algunos desarrollos notables dentro de este ámbito de estudio son por ejemplo, trajes inteligentes de protección para bomberos, personal de rescate o protección química. Encontramos proyectos como PROeTEX (Stephanidis, Antona, & Ntoa, 2021) o estudios como (Schneegass & Voit, 2016) para detección de caídas usando tecnología wearable que provocan una reducción del tiempo de respuesta. En cuanto al diseño se deben considerar diferentes factores como la compatibilidad, interoperabilidad, modularidad o ergonomía, siendo de vital importancia que el dispositivo se adapte a la persona y este pueda llevarlo cómodamente en su uso diario, tal y como podemos ver en (Tao, 2005). Algunos trabajos se centran en utilizar los EPIs para ampliar las capacidades del individuo y controlar su estado (Chae et al., 2017; Podgorski et al., 2017; S. M. Sánchez, 2019; Tulshyan, Sharma, & Mittal, 2020). Por ejemplo, en profesiones como la pesca, se integran en la ropa de protección sistemas de alerta y supervivencia, como un pulmón artificial, un sistema de flotación y una luz de emergencia. El traje, de color muy visible, avisa a la estación base de rescate y da la posición mediante el Sistema de posicionamiento global (Global Positioning System – GPS) del traje. En el caso de los bomberos, se han desarrollado trajes que integran sensores vitales y ambientales, cuyo objetivo es monitorizar al individuo de forma remota y proporcionarle información sobre su entorno y alertarle de posibles peligros a través de una pantalla de visualización (Head-up Display – HUD).

Smart PPE es un proyecto inspirado en la epidemia de ébola en África durante 2013-2016 y que se ha revitalizado con la actual pandemia. El proyecto pretende rediseñar los equipos de protección personal utilizados por los trabajadores sanitarios y el personal esencial durante las pandemias. El traje de protección consiste en una única pieza protectora que busca facilitar el uso del traje y reducir el contacto cuando el individuo se

viste o desviste. El traje está equipado con sensores de temperatura, humedad, y calidad del aire dentro del traje, y un sistema de ventilación integrado que pretende mantener al individuo a una temperatura cómoda para que pueda vestirse y desvestirse. (Fischer II, Weber, & Wohl, 2015; Islam, 2020; Rajendran, Wahab, & Yeap, 2020).

El reconocimiento de la actividad humana (Human Activity Recognition - HAR) ha atraído la atención de la comunidad científica por sus características de apoyo personalizado en diferentes aplicaciones desde los años 80, y se ha estudiado ampliamente en la última década. Dependiendo del propósito de la aplicación, se utilizan porciones contiguas de flujos de datos para detectar y clasificar el comportamiento humano, el preprocesamiento de los mismos transforma los datos de la señal en bruto, clasificándolos posteriormente en vectores de características. Algunos de los ejemplos más notables son detectar el movimiento, cuando una persona está caminando o corriendo (Fahim, Fatima, Lee, & Park, 2013; Kwapisz, Weiss, & Moore, 2011; Lara & Labrador, 2012), rastrear el estado emocional (Rachuri et al., 2010), o clasificar patrones de sueño y ejercicio (Consolvo et al., 2008). Para ello se utilizan normalmente acelerómetros o IMUs, ayudados de algún tipo de algoritmo, con los que detectar el número de pasos dados y monitorizar la actividad física del usuario (M. Chen, Zhang, Qiu, Guizani, & Hao, 2018; Perez, Mata, Rodriguez, & Zhang, 2015; D. Shin, Shin, & Shin, 2014; D.-M. Shin, Shin, & Shin, 2013) e incluso detectar caídas (Mukhopadhyay, 2014), ataques epilépticos (Gope, 2015), y grados de temblor que se producen en personas con la enfermedad de Parkinson (Wile, Ranawaya, & Kiss, 2014). Es notable saber que gracias a la combinación de acelerómetros, giroscopios o (IMUs) y algoritmos, podemos alcanzar una alta precisión (Karakaya, Sengül, & Bostan, 2017; Reeder & David, 2016), como se demostró en el Smartwatch Pebble que utilizó el algoritmo Gráfico de control de la suma acumulada (Cumulative Sum Control Chart – CUSUM) (Maglogiannis, Ioannou, Spyroglou, & Tsanakas, 2014) o técnicas avanzadas de ordenación y filtrado de Kalman para la detección de caídas (D. Shin et al., 2014).

Algunas de las investigaciones más interesantes en este ámbito fueron las realizadas por (Godfrey, Conway, Meagher, & ÓLaighin, 2008), que identificó los elementos biomecánicos subyacentes necesarios para entender y estudiar el movimiento humano. Por su lado, Yasuaki Ohtaki *et al.* desarrolló un método para investigar la cinemática y la dinámica de la locomoción sin limitaciones de laboratorio. (Ohtaki, Sagawa, & Inooka, 2001). (Zampella, Khider, Robertson, & Jiménez, 2012) propuso el uso del filtro de

Kalman no centrado (Unscented Kalman Filter - UKF) como algoritmo de integración para las mediciones inerciales. También (Zhou, Jing, Wang, & Cheng, 2012) presentó un microdispositivo portátil basado en un acelerómetro de tres ejes, que puede detectar cambios en la aceleración del cuerpo humano en función de la posición del dispositivo. En 2009, Chun Zhu y Weihua Sheng desarrollaron un método para el reconocimiento de las actividades humanas cotidianas, que consistía en fusionar los datos de dos sensores inerciales portátiles colocados en el pie y la cintura del sujeto (C. Zhu & Sheng, 2009). Es este campo, el rango de aplicaciones con teléfonos móviles es amplísimo (Incel, Kose, & Ersoy, 2013), especialmente en la monitorización de la salud, que puede ser asociada a un contexto y realizar un rastreo.

El estudio e investigación de la monitorización de las constantes vitales humanas ha sido de gran interés por su repercusión en muy diferentes áreas y de los cuales se han recopilado las investigaciones más relevantes en el campo de los EPIs inteligentes y en el estudio de equipos similares a los desarrollados en nuestra investigación. El objetivo de todos ellos es implementar la capacidad de recoger la información de los trabajadores y detectar si hay algún tipo de peligro para utilizando las tecnologías de comunicación podamos alertar de forma efectiva a la persona adecuada. Garantizar el bienestar físico de los trabajadores es responsabilidad de los empresarios y hoy en día, se ofrece una mejor protección a los trabajadores gracias a los cascos EPI que protegen al trabajador de los golpes en la cabeza. Sin embargo, en algunos casos es importante vigilar otros aspectos para la seguridad del trabajador. (P. Li, Meziane, Otis, Ezzaidi, & Cardou, 2014) desarrollaron un casco que, mediante sensores, mide el impacto de los golpes en la cabeza del trabajador y que también integra la detección de la actividad cerebral. (Qiang, Ji-Ping, Zhe, & Fan, 2009). implementa sensores para el análisis de variables como la humedad, la temperatura y el metano en las minas y transmitiendo la información recogida con Zigbee, disminuyendo el riesgo de sufrir un accidente durante el proceso de extracción de carbón. Otro ejemplo en el ámbito de la minería es el de (Nithya, Ezak, Kumar, Vignesh, & Vimala, 2018) donde se hace un monitoreo de las constantes vitales y se incorpora un botón de emergencia, también utilizando Zigbee para la transmisión de los datos, sus objetivos eran el control del estado de salud del trabajador, alertar de la presencia de peligro o avisar en caso de emergencia a otra persona responsable. En cuanto al movimiento y caídas, la identificación rápida es fundamental para actuar con la mayor rapidez ante lesiones físicas o accidentes graves. Este concepto fue implementado

por (Williams, Doughty, Cameron, & Bradley, 1998), donde se implementan sensores de choque piezoelectrómicos para detectar el impacto y un interruptor o switch de inclinación de mercurio con el que detectar la orientación del individuo cuando se produce una caída. Uno de los sensores más utilizado en las investigaciones es el acelerómetro, por ejemplo (Kim, Wang, Min, & Lee, 2018), lo utiliza con el objetivo de detectar si el casco de protección se lleva puesto de forma correcta, incorrecta o no se lleva mientras el trabajador realiza sus tareas.

Encontramos también otros elementos EPIs de interés como los cinturones, en donde se pueden analizar también las posturas corporales, la movilidad o el gasto energético del trabajador, gracias a el uso de sistemas embebidos integrados en el cinturón se permite identificar las causas que provocan las caídas del trabajador o cómo los cambios en las actividades diarias alteran su estado físico (Prado, Reina-Tosina, & Roa, 2002). También encontramos implementaciones de detectores de caídas vinculados a elementos mecánicos, como sistemas de auto inflado, donde se proponen métodos que detectan la superación de un umbral preestablecido y en un tiempo inferior a 70 ms reaccionan antes que se produzca el impacto (G. Wu & Xue, 2008). Por su lado, (Sabatini, Ligorio, Mannini, Genovese, & Pinna, 2015) implementa un sensor de altímetro-barométrico para detectar la velocidad vertical y la altura del cuerpo, identificando las modificaciones en el movimiento del individuo para detectar los impactos causados por las caídas del individuo, de este modo se pueden verdaderos positivos y verdaderos negativos durante el proceso de análisis. Además, (Fortino, Galzarano, Gravina, & Li, 2015) propuso *C-SPINE*, un ecosistema para Redes colaborativas de sensores corporales (Collaborative Body Sensor Networks - CBSN), donde mediante datos multisensoriales y computación distribuida, los diferentes CBSNs interactúan. Definimos pues los CBSN son redes de sensores corporales que tienen la capacidad de interactuar y apoyarse mutuamente para realizar una tarea. Para demostrar su eficacia, implementaron e-Shake, un sistema colaborativo de CBSN para detectar emociones.

Relativo a investigaciones en los que se explora el uso de brazaletes y pulseras inteligentes, entre esas propuestas se encuentra la patente USD535205S1 (Frederick, 2017), realizada en Estados Unidos e inventada por Walter H. Frederick et al., con un diseño de reloj. Otra patente registrada en Estados Unidos US20170027511A1 fue el dispositivo inventado por (Connor, 2020), gadget que se puede llevar en el brazo con sensores biométricos ajustados como sensores espectroscópicos que proyectan luz sobre

la superficie del brazo en diferentes ángulos. En este caso, se utilizaron sensores de energía electromagnética que miden la impedancia, la resistencia, la conductividad o la permitividad de los tejidos. Uno de los enfoques principales de esta patente es medir los niveles de oxígeno, glucosa, hidratación e incluso el ritmo cardíaco del individuo; en otras palabras, esta patente se centra en medir los signos vitales de la persona, donde se incluye el diseño propuesto de forma general. Por su lado, la patente estadounidense, US20190339688A1 , inventada por Charles Howard Cella et al., propone un sistema de monitorización y vigilancia con el objetivo de recoger los datos en entornos industriales en lo que se puede englobar como el Internet de las Cosas Industriales (IIoT). Este sistema se caracteriza por servir como sistema de gestión inteligente de datos para procesos industriales, al cual se le puede añadir un colector de datos y acoplarlo a múltiples sensores analógicos. Asimismo, la estructura del circuito de almacenamiento y análisis de datos le permite seleccionar un plan de gestión de recogida de datos con cuál, una vez que estos sean procesados, se puedan tomar decisiones con los actuadores (Cella, Duffy, & JR., 2019).

(Magno et al., 2016) presentó el diseño y la implementación de una pulsera inteligente basada en sensores con la característica de recoger la energía del entorno y humano para su funcionamiento sin carga eléctrica, llamada InfiniTime, a la que se sometió a una evaluación de campo. El sistema con un diseño wearable, integraba sensores de temperatura y un acelerómetro, así como una cámara de muy bajo consumo y un micrófono. El propósito de la pulsera es la autosostenibilidad mediante el uso de células solares y generadores termoeléctricos (TEG) para aprovechar el calor corporal. En noviembre de 2013, Martin Ouwerkerk et al. desarrollaron una pulsera con sensores inalámbricos basada en una pulsera anterior cuyo software se optimizó para una larga duración de la batería(Ouwerkerk et al., 2013).

En cuanto a los parámetros que pueden ser medidos por este tipo de dispositivos, cabe destacar el GPS, para la localización del usuario que lleva el Smartwatch (M. Chen et al., 2018; Gope, 2015; Nguyen, 2017; Parara & Sekka, 2016). En otros casos, la triangulación (D. Shin et al., 2014) ofrece mayor precisión, como por ejemplo en estudios realizados para pacientes con demencia, con la idea de mejorar sus condiciones de vida (D.-M. Shin et al., 2013).

También encontramos ejemplos en la medición de la frecuencia cardíaca (Alsulami,

Atkins, & Campion, 2016), y algunos estudios en la literatura emplean un sensor óptico para la monitorización de la frecuencia cardíaca (Manisha, Neeraja, Sindhura, & Ramaya, 2016; Perez et al., 2015; Reeder & David, 2016). Otros estudios tratan de la monitorización de la frecuencia cardíaca, utilizando una técnica denominada fotopletismografía (Kumari, Mathew, & Syal, 2017; Mukhopadhyay, 2014; Sendra, Parra, Lloret, & Tomás, 2018), gracias a la cual, a partir de un haz de luz, se puede medir el volumen del órgano determinado, y en la mayoría de los casos, se utiliza para calcular la cantidad de oxígeno en la sangre.

Entre los productos wearables, encontramos muchos productos comerciales que permiten monitorizar las constantes vitales y permiten la interacción, como los SmartWatch (Apple Watch Series 5, Amazfit, Samsung Galaxy watch 2, Huawei Smartwatch, Xiaomi mi band 4, etc.). Entre sus características, estos incluyen una gran variedad de sensores y funciones, que los hacen muy atractivos para su uso diario. Pueden ayudarnos en la monitorización de la salud, la monitorización del sueño, entrenamiento, monitorización de la frecuencia cardíaca y las alertas de inactividad. Ofrecen además utilizadas como alarmas, encontrar el teléfono, llamadas entrantes, notificaciones de mensajes, notificaciones de teléfono, calendario, notificaciones de aplicaciones, previsión meteorológica, desbloquear el teléfono y notificación de eventos. En términos de sensorización, suelen incluir GPS, sensor de ritmo cardíaco, acelerómetros, giroscopios, sensor magnético, sensor de presión, sensor de luz ambiental, sensor capacitivo, Near Field Communication (NFC), Long Term Evolution (LTE) o Wireless Fidelity (Wi-Fi) entre otros.

Recientemente, se han llevado a cabo estudios de investigación relevantes en el ámbito de los smartwatch wearables, por ejemplo, para prevenir la propagación del COVID-19, así como para identificar la enfermedad en una fase mucho más temprana, reducir la tasa de mortalidad y monitorear la temperatura corporal, la frecuencia cardíaca y la presión arterial del usuario (Dhull et al., 2020). Otros estudios proponen otras funcionalidades del smartwatch, además de la medición de parámetros. Por ejemplo, la investigación de Adjiski Vancho et al. propone el desarrollo de una arquitectura que puede utilizarse en la minería subterránea y que utiliza sensores fijados a la ropa habitual de los EPI, incluidos los cascos y las gafas de seguridad. Estos sensores se conectan al smartphone y al smartwatch a través de sensores Bluetooth de baja energía, para proporcionar seguridad en tiempo real, conocimiento de la situación y predecir

incidentes de salud y seguridad antes de que ocurran (Adjiski, Despodov, Mirakovski, & Serafimovski, 2019). Los recientes avances tecnológicos han revolucionado la tecnología vestible, especialmente en 2002, cuando la conectividad Bluetooth permitió la interacción inalámbrica entre dispositivos, y ha experimentado una enorme expansión en las dos últimas décadas (Bonato, 2010; Park & Jayaraman, 2003). Con un mercado en continuo crecimiento, el número de aplicaciones y formatos wearables de este tipo no ha dejado de aumentar. Teniendo en cuenta la disponibilidad y la viabilidad de las tecnologías wearables y su capacidad para formar parte de la vida cotidiana de cualquier individuo, son el candidato perfecto para la implantación de equipos de protección individual en el entorno laboral. Como es lógico, no todas estas adaptaciones han tenido éxito comercial, ya sea porque la población a la que iban dirigidos no era lo suficientemente grande o por la existencia de otras soluciones más ergonómicas.

2.4. Integración de Inteligencia Artificial

En cuanto a los modelos de inteligencia artificial, el área del mantenimiento y la seguridad laboral en la industria también se ha abordado de diferentes medios. Normalmente, los sistemas encargados de la seguridad de los trabajadores están diseñados para satisfacer las necesidades específicas de una empresa y tienden a reaccionar ante estímulos medidos, siempre que éstos alcancen un umbral mínimo (acción-reacción), lo que presenta poca capacidad de adaptación o modificación del comportamiento ante nuevas situaciones. Por otro lado, los sistemas de IA en los que se introducen mecanismos de aprendizaje basan su planteamiento en un conjunto de reglas que, combinadas con el conocimiento almacenado obtenido a partir de soluciones a problemas conocidos, tratan de predecir el resultado de experimentos inéditos. El uso de redes neuronales (NN) (Yegnanarayana, 2009), sistemas de razonamiento basado en casos (CBR) (Leake, 1996), aprendizaje profundo (DL) (Goodfellow, Bengio, & Courville, 2016) o algoritmos neuro-simbólicos híbridos (Riverola & Corchado, 2000) permiten al sistema determinar si una situación dada supone un riesgo, en función de determinadas condiciones de contorno (el funcionamiento normal de una máquina puede suponer un riesgo para un trabajador en determinadas circunstancias y éstas no tienen por qué ser estáticas). Asimismo, en diferentes trabajos centrados en redes complejas (Silva & Zhao, 2016; Stephenson, Amarasinghe, Martin, & O'Reilly, 2003), se ha demostrado que el análisis de la información en forma de grafos

permite una estructuración más completa ya que la información no lineal puede ser tratada de forma intuitiva, por lo que se ha tratado de trasladar diversas técnicas de aprendizaje automático a redes complejas, donde se pueden predecir los enlaces entre nodos o las relaciones en función de la información previa. En cuanto a los modelos de inteligencia artificial, (Reynolds, 2009) presentó las principales características del GMM, que es una función de densidad de probabilidad paramétrica representada como una suma ponderada de las densidades de los componentes gaussianos. También se han realizado otras investigaciones sobre el mismo modelo de IA (M. Chen et al., 2018; Rasmussen, 1999; Zivkovic, 2004). Este modelo ha sido ampliamente utilizado para detectar anomalías debido a sus características ideales (M. Chen et al., 2018; Laxhammar, Falkman, & Sviestins, 2009; L. Li, Hansman, Palacios, & Welsch, 2016; Zong et al., 2018); con un buen desempeño para encontrar alteraciones en los datos que deben estar en una determinada distribución o para detectar posibles problemas en un entorno laboral donde el riesgo a corto o largo plazo de sufrir un accidente, trastorno o fractura es alto (Casado-Vara, Chamoso, et al., 2019; Casado-Vara, Novais, Gil, Prieto, & Corchado, 2019; Casado-Vara, Prieto-Castrillo, & Corchado, 2018; Chamoso, González-Briones, Rivas, De La Prieta, & Corchado, 2019; Chamoso, González-Briones, Rodríguez, & Corchado, 2018; Chamoso, Rodríguez, de la Prieta, & Bajo, 2018).

En 2019, se emplearon algoritmos de aprendizaje automático (Machine Learning - ML) para la predicción y clasificación de la gravedad de los accidentes de motocicleta en una investigación realizada por (Wahab & Jiang, 2019). Las técnicas basadas en el aprendizaje automático son modelos no paramétricos sin ninguna presunción de las relaciones entre las variables endógenas y exógenas. Otro de los objetivos de este trabajo fue evaluar y comparar diferentes enfoques para modelar la gravedad de los accidentes de motocicleta, así como investigar los factores de riesgo involucrados y los efectos de los accidentes de motocicleta. (Bleser et al., 2015) diseñó un concepto escalable y un demostrador de sistema integrado. La idea básica es aprender los flujos de trabajo a partir de la observación de múltiples operadores expertos y luego transferir los modelos de flujo de trabajo de aprendizaje para demostrar la gravedad de las colisiones de motocicletas. En 2019, un sistema de videovigilancia inteligente que detectaba motocicletas de forma automática fue desarrollado por (Yogameena, Menaka, & Perumaal, 2019). Su objetivo era identificar si los motociclistas llevaban o no cascos de seguridad. Si se encontraba a los motociclistas sin el casco, se reconocía su número de matrícula (License Plate

- LP) y la policía de tráfico o la autoridad judicial tomaban medidas legales contra ellos, como la asignación de puntos de penalización en la licencia del vehículo de los motociclistas y el número Aadhar (Aplicable al escenario indio). En 2017, se presentó una comparación de cuatro métodos estadísticos y de ML por (Iranitalab & Khattak, 2017), incluyendo Modelo lógico multinomial (Multinomial Logit - MNL), Nearest Neighbor Classification (NNC), Support Vector Machines (SVM) y Random Forests (RF), en relación con su capacidad para predecir la gravedad de los accidentes de tráfico. Se desarrolló con un enfoque basado en los costes de los accidentes, con los para comparar los métodos de predicción de la gravedad e investigar los efectos de los métodos de agrupación de datos -K-means Clustering (KC) y Latent Class Clustering (LCC) en el rendimiento de los modelos de predicción. Como conclusión, estas soluciones que empleaban la inteligencia artificial y el aprendizaje automático, supusieron una mejora significativa en los diferentes escenarios.

En 2005, se presentaron los resultados obtenidos con el clasificador de bosque aleatorio en la investigación de (Pal, 2005) y se comparó su rendimiento con el de las máquinas de vectores de soporte (SVM) en términos de precisión de clasificación, tiempo de entrenamiento y parámetros definidos por el usuario. En enero de 2012, V. F. Rodríguez-Galiano *et al.* exploró el rendimiento del clasificador RF para la clasificación de la cobertura del suelo de un área compleja (Rodríguez-Galiano, Ghimire, Rogan, Chica-Olmo, & Rigol-Sánchez, 2012); la evaluación se basó en varios criterios: precisión de la cartografía, sensibilidad al tamaño del conjunto de datos y al ruido. Asimismo, (Azar, Elshazly, Hassanien, & Elkorany, 2014) propuso un enfoque de clasificador de bosque aleatorio (RF) para el diagnóstico de enfermedades linfáticas. En abril de 2016, el uso del clasificador RF en la teledetección fue revisado por (Belgiu & Drăguț, 2016). Además, en 2015, Esrafil Jedari investigó varios enfoques de aprendizaje automático, como el de los vecinos más cercanos (k-Nearest Neighbours - k-NN), un clasificador basado en reglas (JRip) y un bosque aleatorio. (Jedari, Wu, Rashidzadeh, & Saif, 2015) investigaron en el posicionamiento en interiores basado en Wi-Fi, para ubicar usuarios u objetos utilizando el método de huella digital basado en Received Signal Strength Indicator (RSSI), empleando además un clasificador de bosque aleatorio. Por último, (Khalilia, Chakraborty, & Popescu, 2011) presentó un método que utiliza el conjunto de datos del Proyecto de Costes y Utilización de la Sanidad (Healthcare Cost and Utilization Project - HCUP), para predecir el riesgo de enfermedad en los individuos sobre la base

de datos de su historial médico.

Con respecto a la CNN (Shine & CV, 2020) presentaron un sistema automatizado para la identificación de motociclistas sin casco a partir de vídeos de vigilancia del tráfico en tiempo real. Se utilizó un clasificador de dos etapas para detectar motocicletas en los vídeos de vigilancia. Las motocicletas detectadas fueron alimentadas en una etapa de identificación de casclos basada en una CNN. Además, en julio de 2019, el mismo enfoque para detectar la ausencia de casclos en motociclistas con o sin casco fue presentado por (Yogameena et al., 2019); se diferenciaba en que combinaba una CNN con un modelo de mezclas gaussianas (GMM) (T.-c. Li, Su, Liu, & Corchado, 2017). También, en 2020, un sistema que utiliza el procesamiento de imágenes y las redes CNN fue desarrollado por (Raj, Chairat, Timtong, Dailey, & Ekpanyapong, 2018) para la identificación de los motociclistas que violan las leyes del casco. El sistema incluye la detección de motocicletas, la clasificación de casclos vs. sin casclos y el reconocimiento de matrículas de motocicletas.

El reconocimiento de la actividad humana (HAR) ha cobrado gran interés en varios sectores, entre ellos el de la PRL. Su desarrollo se ve favorecido por el desarrollo de sistemas multisensoriales, que utilizan una combinación de unidades de medición inercial (IMU) en el cuerpo. El objetivo es identificar y detectar actividades; sin embargo, se trata de una tarea compleja ya que los datos son ambiguos o tienen ruido. Por lo tanto, se requieren modelos basados en el aprendizaje automático para aprender de los datos y extraer conocimientos y detectar y clasificar patrones de comportamiento (Y. Chen et al., 2016; Ordóñez & Roggen, 2016; Singh et al., 2017). Numerosos trabajos exploran el uso de estas técnicas como Naïve Bayes (NB) (E. M. Tapia, Intille, & Larson, 2004), Árboles de Decisión (Bao & Intille, 2004), Hidden Markov Modeling (HMM) (Duong, Bui, Phung, & Venkatesh, 2005), Redes Neuronales (NN) (W. Wu et al., 2012), Máquinas de Vectores de Soporte (SVM) (Y. Zhu, Nayak, & Roy-Chowdhury, 2012), y Redes de Creencia Profunda (Deep Belief Networks - DBN) (Plötz, Hammerla, & Olivier, 2011), consideramos algunas de las implementaciones más relevantes. Si bien es posible analizar alertas como la detección de caídas en función de si el valor obtenido por el sistema embebido supera un valor umbral establecido. Utilizando técnicas de Machine Learning (ML) y Supervised Learning, se generan resultados con mayor precisión (Pozna, Precup, Tar, Škrjanc, & Preitl, 2010; Sarma, 2009) demostrando su éxito en diversas aplicaciones. Esto se hace gracias a la recopilación previa de

información, que se procesa después mediante modelos de Redes Neuronales (NN), Redes Neuronales Convolucionales (CNN), Árboles de Decisión, Bosques Aleatorios, etc. Gracias a la implementación de ML y Aprendizaje Supervisado se consigue dotar a los EPI de la capacidad predictiva, enfocando sus capacidades para ser implementados como Equipos de Protección Industrial Predictivos (EPPI), obteniendo un resultado con mayor precisión respecto a los modelos ML implementados (Gil, Johanyák, Kovács, & et al., 2018; Nowaková, Prílepkov, & Snášel, 2017). También es posible implementar la fusión de sensores, lo que genera consecuentemente una mayor precisión en las técnicas de IA, ya que proporcionan información adicional al entorno del usuario. Como se muestra en (Gjoreski, Lustrek, & Gams, 2011), se implementaron acelerómetros integrados a sistemas embebidos, colocados en el brazo o la cintura del individuo para detectar posiciones que indiquen la caída del individuo, mejorando la precisión de las técnicas de IA implementadas. (Boutellaa, Kerdjidj, & Ghanem, 2019) implementa la fusión de sensores wearables utilizando una matriz de covarianza para la extracción de características, consiguiendo una alta eficacia en la detección de caídas. (Huang, Chen, & Liao, 2018) propone el uso de un sistema electrónico colocado en el cinturón del individuo con capacidad de detección de caídas basado en el comportamiento corporal, en este caso el dispositivo presenta una precisión del 70-80 % al implementar Máquinas de Soporte Vectorial. Según las investigaciones de la literatura en este ámbito, es importante que durante el proceso de obtención de datos en entornos reales, no se sobreajusten los modelos implementados en ML, ya que pueden presentar problemas cuando se aplica en la realidad frente a la etapa de evaluación (Krupitzer et al., 2019). También, durante el proceso de recogida de datos, se deben investigar las diferentes situaciones en las que el sensor detecta las situaciones de riesgo presentadas (Nouri, Omidvari, & Tehrani, 2010).

Existen algoritmos inteligentes capaces de recoger los datos, analizarlos y decidir si se trata de un falso positivo, un valor esperado o si se está produciendo una emergencia, gracias a la programación previa de los datos monitorizados. Se programan valores mínimos y máximos y, si estamos entre ellos, significa que el estado del paciente es normal. Es fundamental destacar que este algoritmo aprende; es decir, si el sistema alerta de una anomalía que luego es valorada por el médico como un falso positivo, el algoritmo no volvería a cometer ese error (Manisha et al., 2016). Otro ejemplo de recogida y análisis de datos es el Rapid Miner (Kajornkasirat, Chanapai, & Hnusukan, 2018) o el uso de un sistema experto, como el Sistema basado en el conocimiento (Knowledge Based

System - KBS), capaz de tomar decisiones y actuar en los casos en los que el paciente supere los umbrales establecidos (Alsulami et al., 2016). En materia de monitorización del estado psicológico del usuario, encontramos las arquitecturas de Soporte de salud inteligente del personal (Smart Personal Health Advisor - SPHA) (M. Chen et al., 2018) que proporcionan al usuario una guía de vida personalizada para sus actividades diarias e interacción con su entorno. En esta última investigación, Chen, M. et al. utilizan textiles inteligentes para la monitorización, con los que recogen los datos fisiológicos del usuario, con sensores para medir el electrocardiograma, la temperatura y la cantidad de oxígeno en la sangre.

2.5. Plataformas y arquitecturas para la prevención

El uso de las diferentes tecnologías habilitadoras de la Industria 4.0 ha llevado a la creación de nuevas plataformas y a la mejora de la calidad de la información obtenida. Las plataformas de la Industria 4.0 son capaces de procesar datos y comprender su significado; una característica que puede revolucionar las industrias actuales, ya que la mayoría de las plataformas actuales no aplican estas nuevas tecnologías (Cella, Duffy, & McGuckin., 2019; Dupuis & Zerlett, 1987; Gardner, 2003; Maria, Sever, & George, 2018). En la última década se han introducido en el mercado plataformas que implementan estrategias de soporte predictivo (Chamoso, Paz, Bajo, & Villarrubia, 2016; Chimeno et al., 2018; Porter & Heppelmann, 2015; Puig Ramírez, 2010; Rodríguez & Corchado, 2020). Estas soluciones monitorizan a los trabajadores y su entorno a través de la captación de datos por parte de sensores, permitiendo maximizar la efectividad de estrategias de seguridad. La irrupción de tecnologías, como el BigData, también ha favorecido el procesamiento de datos en tiempo real, a los que se pueden aplicar técnicas de minería de datos en procesos industriales a gran escala (Yao et al., 2015). Otra tendencia actual en este tipo de plataformas es utilizar arquitecturas en la nube para procesar grandes cantidades de datos, ofreciendo soluciones enmarcadas en software, plataforma e infraestructura. Este tipo de arquitectura, combinada con organizaciones virtuales de agentes, permite que la plataforma sea modular y escalable, facilitando la incorporación de nuevas soluciones verticales integradas en el diseño horizontal de la plataforma (De la Prieta, Gil, Rodríguez-González, & Corchado, 2014; Heras et al., 2012). Además, con el uso de tecnologías, como el Edge Computing, es posible

proponer entornos capaces de procesar la información cerca del dispositivo, lo que permite gestionar los datos de forma más eficiente y racional (Shi & Dustdar, 2016). La tendencia es integrar las capacidades de AIoT o Smart Data en las plataformas, capaces de procesar y combinar datos de diferentes fuentes, como el ERP, la gestión de operaciones de fabricación (Manufacturing Operation Management - MOM), el Sistema informático de gestión del mantenimiento (Computerised Maintenance Management System - CMMS), el control de supervisión y adquisición de datos (Supervisory Control and Data Acquisition - SCADA), el Internet industrial de las cosas (IIoT), las vibraciones, el ruido o los informes de incidencias en tiempo real. Esta capacidad puede integrarse con otras innovaciones tecnológicas, como los sistemas cognitivos, que se desarrollan mediante la aplicación de la inteligencia artificial a los datos, las redes neuronales convolucionales (CNN) y el aprendizaje profundo por refuerzo (Deep Reinforcement Learning - DRL), lo que permite construir herramientas capaces de controlar un enorme conjunto de parámetros relacionados con los procesos y el entorno. El objetivo es obtener un conocimiento exhaustivo de la situación de los trabajadores e incorporar mecanismos inteligentes para optimizar los procesos, el mantenimiento y la seguridad (Boyes, Hallaq, Cunningham, & Watson, 2018; Chamoso et al., 2019, 2016; Z.-Y. Chen & Kuo, 2017; Mobley, 2002; Puig Ramírez, 2010; Van den Oord, Dieleman, & Schrauwen, 2013).

El paradigma de Computación de Borde o Edge Computing nos permite tomar parte de la carga computacional de la nube a los nodos Edge (Yu et al., 2017). (Shi et al., 2016) definen la computación de borde como recursos de computación y de red ubicados entre las fuentes de datos, como los dispositivos IoT, y los centros de datos de la nube. En estos nodos de borde es posible filtrar, procesar y almacenamiento en caché la información que viene de la capa de IoT y que va a la capa Cloud, balanceado y reduciendo los datos enviados o recibidos a la nube, con la consiguiente disminución de costo de los servicios de computación y almacenamiento en la nube. Los nodos Edge pueden pre-procesar la información recolectada de los nodos en la capa IoT, reduciendo así la información a ser procesada y almacenada en la nube (Sittón-Candanedo, Alonso, Corchado, Rodríguez-González, & Casado-Vara, 2019). Además, es posible ejecutar algoritmos de Aprendizaje Automático (Machine Learning) o incluso de Aprendizaje Profundo (Deep Learning) en los nodos Edge, de manera que se pueda dar un servicio más directo a los usuarios, reduciendo los tiempos de respuesta. También es posible

seguir prestando servicio temporalmente durante las interrupciones de la comunicación con la nube (Sittón-Candanedo, Alonso, García, Muñoz, & Rodríguez-González, 2019).

Existe una amplia variedad de escenarios en los que se aplican soluciones basadas en IoT y el Edge Computing (Alonso, Sittón-Candanedo, Casado-Vara, Prieto, & Corchado, 2020). Entre las aplicaciones más relevantes se encuentran las soluciones de Smart Farming (Alonso, Sittón-Candanedo, García, Prieto, & Rodríguez-González, 2020), Smart Energy (Sittón-Candanedo, Alonso, García, Gil, & Rodríguez-González, 2019) , Industria 4.0 o incluso detección de incendios para la protección de espacios naturales (Avgeris et al., 2019), entre muchas otras. Además, aunque existen escenarios en los que el Edge Computing se aplica a un solo entorno como sistema ad-hoc, también hay desarrollos dirigidos a proporcionar funcionalidades de borde como plataforma. Podemos así pues, clasificar dos modelos principales a la hora de diseñar soluciones de Edge Computing (Yu et al., 2017). En el modelo jerárquico, la arquitectura de borde se divide en una jerarquía en la que se definen funciones basadas en la distancia y los recursos (Jararweh et al., 2016). Y por otro lado, el modelo definido por el software (Puente Fernández, García Villalba, & Kim, 2018), empleado en diferentes escenarios Edge-IoT para reconfiguración dinámica y automatizada de recursos de red (Alonso, Sittón-Candanedo, Casado-Vara, et al., 2020).

Para realizar la computación al borde, empresas como NVIDIA, han incorporado placas de computación embebida como la Jetson Nano. Encontramos algunos ejemplos de su uso, como en el trabajo de (J.-Y. Lee et al., 2015) para detección en tiempo real de las manzanas donde se analiza las imperfecciones y se gestiona su suministro. Otra interesante investigación es la detección de caras y el reconocimiento de emociones faciales, a través de la Jetson Nano y un sistema de visión artificial, utilizando Deep Neural Network (DNN) con OpenCV y el apoyo de una arquitectura ResNet (Sati, Sánchez, Shoeibi, Arora, & Corchado, 2020). En este contexto, un concepto novedoso, Internet de los objetos robóticos (Internet of Robotic Things - IoRT) fue dado por (Araújo, Portugal, Couceiro, & Rocha, 2015). Es un paradigma que comparte ciertos aspectos con el Internet de las Cosas y la Robótica. Por último, tecnologías como Robot Operating System (ROS) y Sistemas Multiagente, son incorporadas a arquitecturas Egde Computing a través de las cuales también se puede detectar de forma eficaz anomalías con procesamiento de datos utilizando TensorFlow y técnicas de Inteligencia Artificial (IA) (S. M. Sánchez et al., 2020).

2.6. Conclusiones

La demanda de servicios de seguridad y salud laboral sigue viéndose impulsada por la implantación de nuevas exigencias en esta materia, así como por la tendencia a la subcontratación de algunos servicios, en detrimento de la autogestión. A su vez, la aparición de nuevos servicios durante 2020 como consecuencia de la pandemia incidió positivamente en el valor del mercado. Sin embargo, el cierre, temporal o definitivo, de empresas de diversos sectores, el descenso del número de personas ocupadas, la inclusión en ERTE de numerosos trabajadores y la extensión del teletrabajo limitaron el crecimiento del mercado, no pudiendo prestarse determinados servicios. Como ya se ha indicado, estamos hablando de un tipo de mercado ya maduro, amenazado en cierto modo por la automatización inherente a la Industria 4.0, donde los competidores luchan por ofrecer precios competitivos y en los que las exigencias legales (y también la cada vez más acusada concienciación) obligan a las empresas a realizar importantes desembolsos en equipos de protección. Esto permite mantener los niveles de ventas, pero fuerzan a los proveedores a seguir estrategias que les permitan diferenciarse de sus competidores, a la vez que permitan cumplir la normativa a un coste razonable. En esta línea, se ha revelado como una tendencia para estos proveedores, la inversión a gran escala en el desarrollo e innovación, como vía para la diferenciación de sus productos, lo que se traduce en un gran interés en integrar tecnologías como IoT, Big Data y computación en la nube, que en el caso con este trabajo, se ven ampliamente rebasadas al incidir en tecnologías de última generación, en estos campos (smart data, Edge Computing, advanced machine learning, predictive algorithms y advanced support decision systems).

En este contexto, si analizamos los proveedores de este tipo de productos, encontramos empresas de ámbito mundial (3M, Siteandfield, General Electric, Honeywell, etc.) cuyo posicionamiento se ha desarrollado a lo largo de décadas y que ofrecen equipos de protección clásicos (cascos, máscaras, guantes, smartwatch, detectores, etc.) de alta calidad, a un precio competitivo y que tratan de incorporar aplicaciones que ofrecen alguna funcionalidad avanzada. En los últimos años, empresas más recientes (DAQRI, Human Condition Safety, Intellinium, Seebo) también se han involucrado en este mercado y apuestan por ofrecer soluciones que integren las nuevas tecnologías, como el Big Data y las soluciones TIC, para potenciar la industria 4.0 con un enfoque especial en la seguridad de los trabajadores y el mantenimiento de las instalaciones (Chamoso et

al., 2017; Gazafroudi et al., 2019; Román, Rodríguez, & Prieta, 2016; S. M. Sánchez et al., 2020; Sittón & Rodríguez, 2017; Sun & Ansari, 2016).

Estas tendencias, en las que se está apostando fuertemente para este 2022, revelan que los sistemas inteligentes, aplicados a la PRL, en su mayoría se limitan a aplicaciones o plataformas que permiten gestionar los recursos EPI, realizando un seguimiento de operaciones y el mantenimiento que se lleva a cabo sobre ellos, pero que no explotan el verdadero potencial que esconden estas tecnologías, provocando la aparición de dos tipos de proveedores muy marcados, los expertos en equipos de protección y los integradores TICs que superponen una capa de gestión, pero que carecen de la integración necesaria para alcanzar todas las ventajas que pueden ofrecer. En este nicho es donde entra en esta investigación, que aporta una plataforma innovadora en prevención, explotando al máximo las posibilidades que ofrece un hardware diseñado de forma conveniente, con funcionalidad ad-hoc para la reducción de un conjunto de problemas de elevada incidencia y que huye de apuestas por sistemas estándar de elevado coste que o bien no resuelven todos los problemas que puede encontrar una empresa en el entorno de trabajo donde los usuarios llevan a cabo sus tareas, o contemplan herramientas y funcionalidades que no se adaptan a sus procesos. En nuestro caso se pretende trasladar las investigaciones en el campo de la PRL y de igual forma que el procesamiento de datos unido a la IA pueda predecir el riesgo en para un operario. Estas mismas herramienta pueden adaptarse, investigando los factores que permiten caracterizar el nivel de riesgo de una actividad (en función del contexto, del trabajador y de los procedimientos que aplica) y determinar si una actividad concreta y la forma en que se desempeña, puede derivar en una patología a largo plazo. Para ello, previa identificación del escenario y caracterización de patologías, riesgos y elementos desencadenantes, se debe establecer una métrica asociada a varios de estos parámetros y basando la investigación en algoritmos híbridos, se tratará de diseñar un motor de inferencia basado en diferentes tipos de redes neuronales, capaz de manejar estas variables multidimensionales y catalogar las situaciones que se están dando en tiempo real (O'Leary, Kuokka, & Plant, 1997).

Capítulo 3

Contribuciones



VNiVERSiDAD
DE SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

Contribuciones

3.1. Introducción

El uso de tecnologías como los wearables, el IoT, la computación de borde combinada con las comunicaciones inalámbricas y la inteligencia artificial para la toma de decisiones puede suponer una importante evolución en la seguridad y la prevención de riesgos laborales tal y como se ha descrito en detalle en los Capítulos 1 y 2. En vista de ello, la implantación de un sistema electrónico de detección de anomalías en el puesto de trabajo combinado de las tecnologías escogidas, puede ser un apoyo esencial para el cuidado del personal.

Actualmente, las empresas del sector industrial centran sus esfuerzos en incorporar los avances incluidos en el modelo de Industria 4.0 para seguir compitiendo en un mercado cada vez más tecnificado. El uso de los EPI inteligentes permite predecir y detectar anomalías en el entorno del trabajador. Para ello, es fundamental que el trabajador pueda adaptarse a las capacidades tecnológicas actuales, es decir, que los dispositivos o EPIs inteligentes tengan la capacidad de transmitir información entre componentes, sean cómodos y permitan la movilidad del trabajador para asegurar la integridad de cada uno de los involucrados en el sistema (Barro-Torres, Fernández-Caramés, Pérez-Iglesias, & Escudero, 2012).

Esta Tesis Doctoral propone la mejora de la seguridad e integridad de los trabajadores mediante la predicción y notificación temprana de las anomalías detectadas en su entorno. Diferentes industrias como la construcción, la minería o la electricidad han comenzado a invertir en la mejora de la seguridad de sus empleados mediante la integración de nuevas tecnologías o ”tecnologías inteligentes.”^{en} el entorno de trabajo. Estas tecnologías se encargan de vigilar y proteger a los individuos en un área de trabajo.

La integración de estos sistemas pretende crear un ecosistema de Equipos de Protección Individual o EPIs para preservar la integridad de los trabajadores. Este aspecto es crucial para una aplicación eficaz de los sistemas, ya que un dispositivo incómodo o voluminoso disuadiría a los trabajadores de su uso.

De lo anterior, se puede concluir que el uso de tecnologías como los wearables, IoT, Edge Computing combinadas con las comunicaciones inalámbricas y la Inteligencia Artificial para la toma de decisiones puede suponer una importante evolución en la seguridad y la Prevención de Riesgos Laborales. En vista de ello, la implantación de un sistema electrónico de detección de anomalías en el puesto de trabajo puede ser un apoyo imprescindible para el cuidado del personal. Se plantea utilizar una detección de anomalías a través de tres dispositivos: un casco (Campero-Jurado, Márquez-Sánchez, Quintanar-Gómez, Rodríguez, & Corchado, 2020), un cinturón (Rodríguez & Corchado, 2020), y una pulsera (Márquez-Sánchez, Campero-Jurado, Robles-Camarillo, Rodríguez, & Corchado-Rodríguez, 2021). Donde una de las principales motivaciones es la generación de una plataforma que integra la tecnología Edge Computing para el apoyo del trabajador que ingiera diferentes fuentes de datos provenientes de EPIs, Equipos de protección Común (EPCs), así como otros datos de interés para tener una estrategia efectiva de prevención de riesgos en el entorno de trabajo. Gracias a las diferentes capas, se permite procesar la información de los diferentes dispositivos, aplicando algoritmos inteligentes para la detección temprana de anomalías y preprocesando los datos antes de ser enviados a la Nube y que se comparan con diferentes modelos de inteligencia artificial.

En este Capítulo se presenta la plataforma propuesta, diseñada de forma modular contemplando futuras integraciones de dispositivos, presentando los bloques en los que se divide y tecnologías que incorpora. Además, en las siguientes secciones se describen los diferentes EPIs desarrollados, integrables en los puestos de trabajo y se analiza cómo gracias al ecosistema de dispositivos conectados a la plataforma combinados de las capacidades que aporta la Inteligencia Artificial, para realizar predicciones y alertar individuo, mejorando su protección (Campero-Jurado et al., 2020; M. Sánchez et al., 2020; S. M. Sánchez et al., 2019). Además, con el uso de Edge Computing, podemos implementar esta solución en zonas con falta de conectividad y de forma relativamente barata, con el consiguiente impacto en la reducción de víctimas o accidentes en cualquier

país (Márquez-Sánchez, Campero-Jurado, Herrera-Santos, Rodríguez, & Corchado, 2021; S. M. Sánchez et al., 2020).

3.2. Estructura plataforma

En esta sección se presenta la plataforma Edge-AIoT, que integra tres capas principales según se ilustra en la Figura 3.1. El diseño de esta plataforma se basa en diferentes tecnologías, que están diferenciadas en las diferentes capas, descritas en profundidad en el Capítulo 2. De forma resumida tendremos una la capa de hardware o IoT, encargada de la captación de datos a través de los diferentes dispositivos y EPIs, y por otro lado, las capas Edge y Cloud, con las cuales se procesan y analizan los datos para la detección y prevención de riesgos y accidentes. A continuación se describen en mayor detalle cada una de ellas:

- **Capa IoT.** En la capa inferior, se han desarrollado diferentes dispositivos en forma de EPIs inteligentes que combinados de dispositivos EPC, monitorean la situación del trabajador y su entorno, y además, se encargan de la recogida y envío de datos. Cada dispositivo por separado realiza una detección de alarmas individuales y posteriormente, se comunica vía Wireless con la capa intermedia en la que se recogen los datos de cada uno y se realiza el procesamiento inicial.
- **Capa Edge.** En esta capa se integra la computación al borde, con la cual se preprocesa toda la información del sistema, aplicando algoritmos inteligentes para la detección temprana de anomalías, avisando directamente a los trabajadores en el caso de alerta y reduciendo así el tiempo de notificación. Posteriormente, envía los datos a la nube de forma ordenada.
- **Capa Cloud.** Finalmente, la información se recibe en un entorno Cloud o en la nube para la visualización de los datos desde la plataforma y la aplicación de modelos de Deep Learning con los que detectar posibles anomalías gracias al entrenamiento del conjunto de datos ingeridos históricamente.

La plataforma propuesta se basa en un elemento central o nodo concentrador, que incorpora la capacidad de procesamiento al borde. Este elemento, es clave en la recogida

de las medidas de los diferentes dispositivos y posteriormente en la comunicación con el servidor en la nube utilizando para la comunicación el protocolo (Message Queuing Telemetry Transport – MQTT), reduciendo reducirá la tasa de envío de datos que no sean esenciales. Se busca una integración modular de los diferentes dispositivos que se desarrollen para posteriormente realizar un análisis de datos. Como concentrador de datos, se utiliza un nodo con características procesamiento al borde, con el que gracias a su potencia de procesamiento y bajo consumo, se permite realizar cálculos intensivos de algoritmos basados en Inteligencia Artificial.



FIGURA 3.1: Arquitectura de la plataforma Edge-AIoT.

3.3. Descripción técnica

En la Figura 3.1 se representa la arquitectura propuesta. Los componentes que integran cada una de sus capas con: IoT, Edge y Cloud, se describen en esta sección.

3.3.1. IoT Layer

La tecnología IoT y wearable han revolucionado el campo de los EPIs inteligentes, permitiendo crear redes de objetos físicos que implementan circuitería electrónica y conectividad a la red, y gracias a esta funcionalidad recojan e intercambien datos con fines específicos (Miorandi, Sicari, De Pellegrini, & Chlamtac, 2012). Estos beneficios ya han sido reconocidos y validados por diferentes industrias con resultados muy positivos. Por ello, se han explorado las diferentes soluciones que pueden integrarse en el dispositivo, optimizando la detección y prevención de riesgos, así como sobre equipos y sistemas auxiliares de detección, alerta e identificación de riesgos. Todo ello es posible gracias a la integración de sensores, actuadores y conectividad. Así, se han analizado las posibilidades de adaptación, desarrollo y optimización de las tecnologías existentes para con el uso de wearables, se pueda realizar una monitorización del estado del trabajador en tiempo real, reconocimiento la actividad humana y establecer si se encuentra dentro de unos umbrales preestablecidos.

Las plataformas que las empresas tienen actualmente en marcha se centran en aspectos de producción y productividad. Sin embargo, la aplicación de medidas de protección, sobre todo cuando no es posible determinar normas que garanticen la integridad del individuo, es un componente para reducir estas causas. Por ello, es importante el uso de EPI, como cinturones, cascos, correctores posturales y otros dispositivos que protejan la integridad física del operario. Por otro lado, el uso de Equipos de protección Común o EPC que monitoricen diferentes parámetros inherentes a la seguridad en los entornos de trabajo aportan un gran valor de información que permite crear también ambientes de mayor seguridad y favorecen aquellas cuestiones de higiene tan importantes dentro del ámbito de la PRL.

Después del estudio un estudio general de los posibles riesgos a los que un trabajador puede verse expuesto en cualquier momento, y conocer de este modo los sectores

en los que se producen dichos riesgos, así como las causas que los originan y los posibles elementos que se podrían utilizar para prevenirlos o combatirlos. Se han diseñado una serie de Equipos de Protección Individual o EPIs que realizan una monitorización de los trabajadores individualmente utilizando sensores implementados en sus ropas y equipos de trabajo. Podríamos destacar entre los ellos la incorporación de sensores de temperatura, impactos, piezoelectrónicos, gases, micrófonos, humedad, presión, acelerómetro, etc. Así como actuadores entre los cuales hay vibradores, Diodos emisores de luz (Light Emitting Diode - LEDs) o altavoces. Para las comunicaciones se han estudiado la tecnología bluetooth, Wi-Fi, radiofrecuencia, ZigBee, etc. Cabe destacar el uso de elementos conductores aplicables a las prendas como tela conductora, hilo conductor, cordón conductor, cable electroluminiscente, etc. También diferentes elementos para dotar de alimentación a la electrónica, como baterías de litio, módulos de carga de batería y módulos de carga inductiva. En la siguiente Figura 3.2 se recogen las características y componentes de cada uno de ellos.



FIGURA 3.2: Dispositivos EPIs Inteligentes integrados en la plataforma.

Los dispositivos presentados en los artículos de este compendio de artículos son un casco, un cinturón y un brazalete, que se pueden integrar en la plataforma propuesta de forma modular junto con otros dispositivos EPI y EPC. Estos dispositivos se describen para cada uno de los desarrollos:

Uno de los desarrollos es un casco inteligente, cuyo principal objetivo es el de proteger al operario de peligros, golpes mecánicos e impactos, al tiempo que controla las variables de su entorno, como la luz, la humedad, la temperatura, la presión atmosférica, la presencia de gases y la calidad del aire. Al mismo tiempo, este EPI inteligente tiene la suficiente capacidad luminosa a través de indicadores lumínicos, para ser visto por otros trabajadores, así como una fuente de luz, que proporcionará una visión adecuada, adaptada a las condiciones de luminosidad del lugar de trabajo (Campero-Jurado et

al., 2020). Como componente para supervisar el aire, los gases nocivos, la presión, la temperatura y la humedad se utiliza el sensor ambiental BME680. Se trata de un sistema microelectromecánico (Micro Electronic Mechanical Systems - MEMS) que integra un sensor de compuestos orgánicos volátiles (Volatile Organic Compounds - VOC), un sensor de temperatura, un sensor de humedad y un barómetro. El sensor implementado para el control del nivel de luminosidad es el sensor de luz ambiental ALS-PT19. El sensor implementado para la detección de golpes es una resistencia de fuerza sensitiva (Force Sensitive Resistor – FSR). El sensor encargado de detectar las caídas sufridas por el trabajador es el módulo MPU6050, un sensor inercial electrónico de seis ejes. La fuente de luz integrada en el casco es una tira de LEDs NeoPixel Adafruit multicolor, que se iluminará de un color diferente en función de la alarma o del estado del entorno. Además el casco integra un altavoz para alertar de que existe una alarma y de una linterna en su parte frontal para iluminar, tal como se mencionaba anteriormente en base a los niveles de luz del lugar. A continuación, en la Figura 3.3 se muestra el casco con la electrónica integrada y el panel de visualización de los diferentes parámetros que mide.

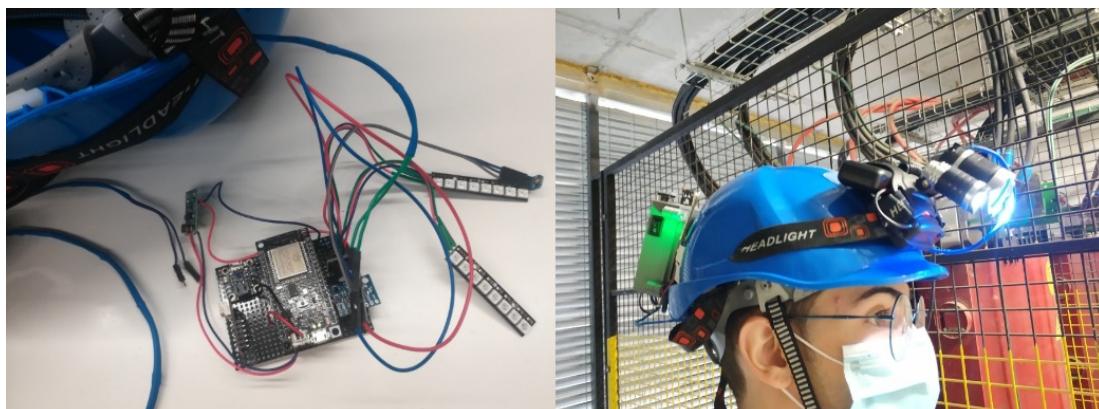


FIGURA 3.3: Casco con la electrónica integrada.

En la Figura 3.4 se muestra la algoritmia y sistema de reglas implementado como firmware en el dispositivo, con la cual realizamos un detección de alertas cuando se sobrepasan ciertos umbrales y en base a ello el casco adquiere un cierto funcionamiento. Además en esta parte se hace una recopilación de las diferentes mediciones para enviarlas a capas superiores.

En el caso del brazalete inteligente, se trata de un PPE wearable, que puede analizar el comportamiento del usuario y que es capaz de establecer estimaciones del estado del trabajador en tiempo real, y determinar si tras la medición de un conjunto de medidas corporales determinadas, el trabajador se encuentra o no, dentro de unos

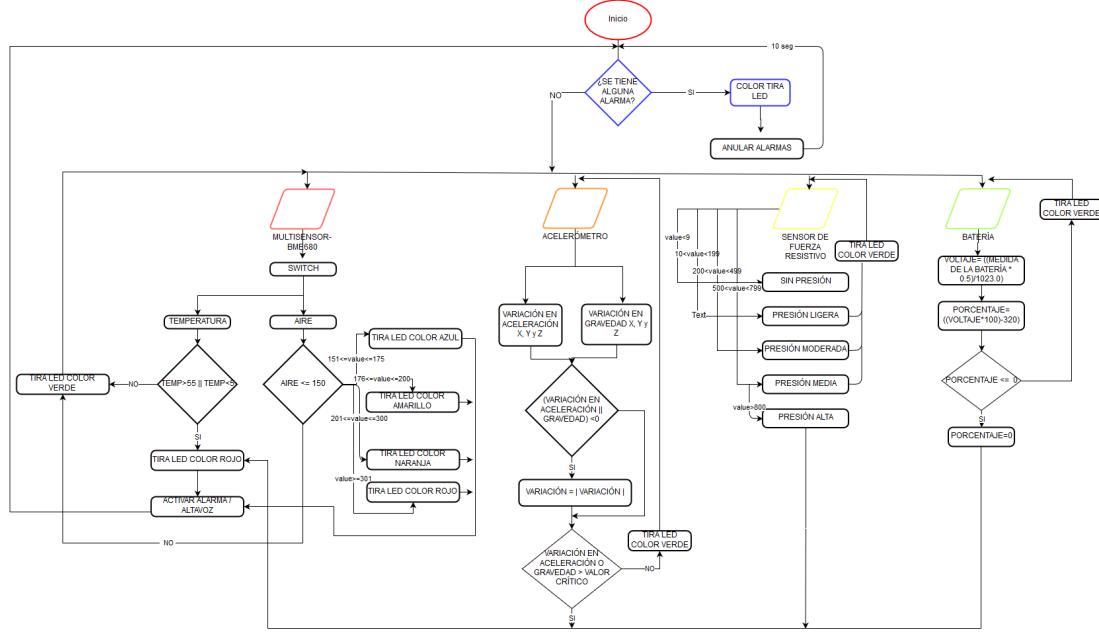


FIGURA 3.4: Diagrama de funcionamiento del firmware del casco.

umbrales preestablecidos. Entre sus características puede medir parámetros como el pulso y la temperatura, y detectar caídas o accidentes. Su fabricación, está hecha con componentes electrónicos soldados a una protoboard flexible. Como microcontrolador se utiliza un ESP32 con pantalla de cristal líquido (Liquid Cristal Display - LCD) y entre sus componentes incorpora como actuadores un zumbador y una tira de LED, y como sensores, un sensor inercial IMU, un sensor de temperatura, sensor de pulso y botón de pánico. El objetivo de este dispositivo es favorecer la interacción con la electrónica, así como realizar una monitorización del usuario y el entorno. Para el reconocimiento de la actividad humana (HAR), se utiliza el sensor inercial (IMU) BMI160 de Bosch, que proporciona una medición precisa de la aceleración y la velocidad angular giroscópica. Para la medición de la temperatura corporal del usuario se utiliza un termopar de tipo K con punta de acero inoxidable aislada de Adafruit (Nueva York, NY, EE.UU.), que gracias a sus prestaciones es ideal para medir la temperatura en contacto con la piel. Para medir el ritmo cardíaco o pulsaciones, se ha utilizado un sensor que se basa en sensores de fotodioidos compuesto de dos emisores y dos receptores de luz, gracias a los cuales se pueden medir los latidos del corazón, recogiendo la variación en cada instante de la luz reflejada; y gracias a ello estimar las pulsaciones por minuto. A continuación, en la Figura 3.5 se muestra el brazalete con el panel y los diferentes indicadores de los sensores.

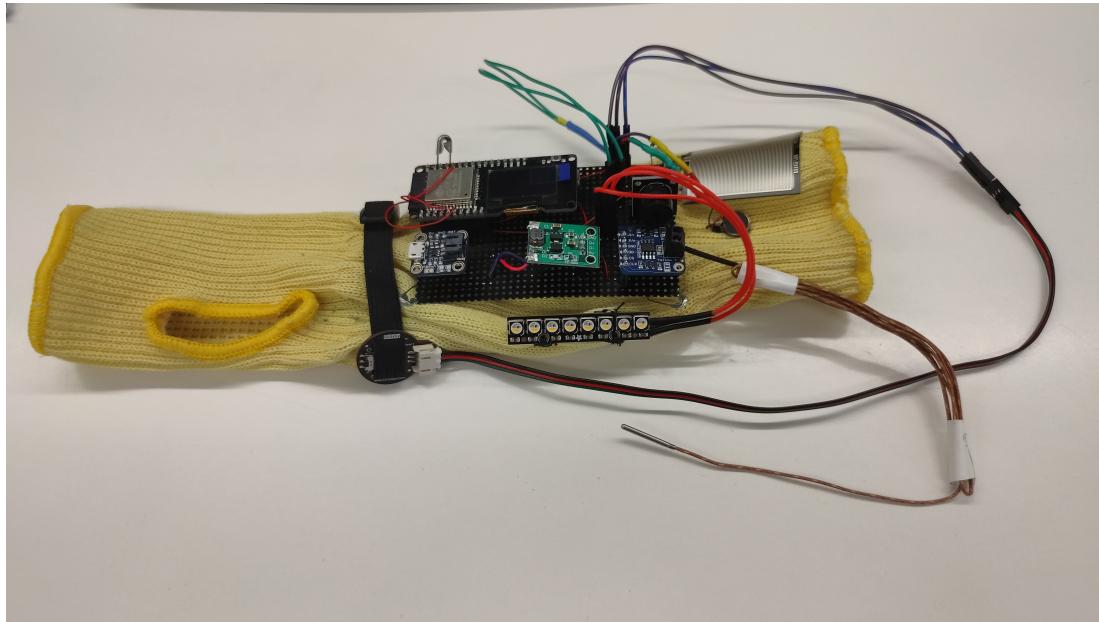


FIGURA 3.5: Brazalete con la electrónica integrada.

En la siguiente Figura 3.6 se muestra el diagrama de flujo del firmware, con un sistema de reglas para la detección de alarmas en el hardware y a su vez la recogida y envío de datos de todos los sensores.

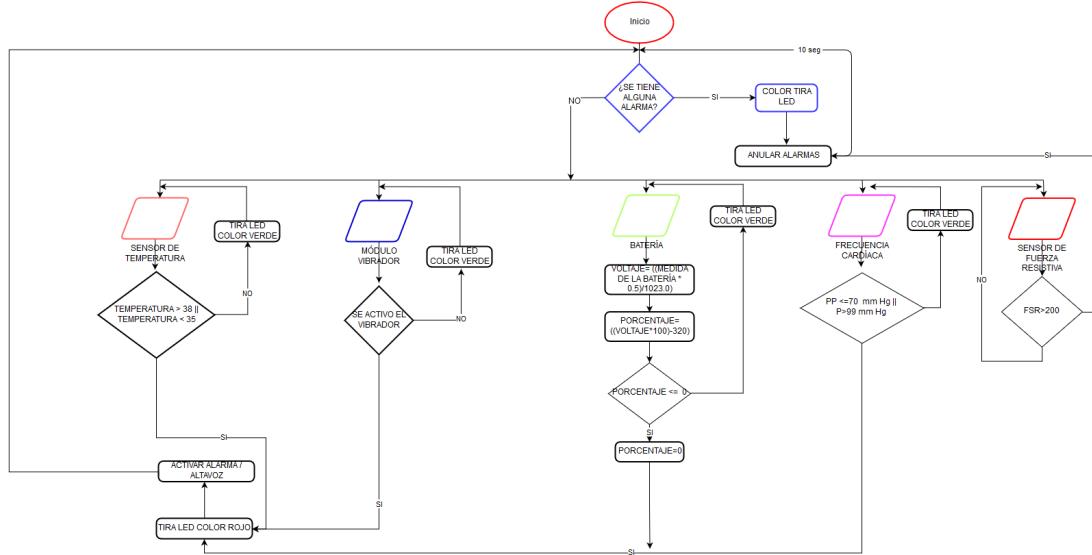


FIGURA 3.6: Diagrama de funcionamiento del firmware del brazalete.

Por último, se ha desarrollado un cinturón inteligente, donde la electrónica y diferentes componentes está integrada en una placa que va cubierta de una carcasa que se ubica en el cinturón. Este tiene la capacidad de detectar las caídas, el nivel de ruido y también hace posible que el trabajador envíe un aviso si se ha detectado una anomalía o si está en peligro, mediante un botón de pánico. Para detectar las caídas se utiliza un

IMU MPU6050, que contiene un acelerómetro y un giroscopio MEMS. Para medir los niveles de ruido se ha utilizado un sensor de sonido KY-038, que es un transductor que convierte las ondas sonoras en señales eléctricas, incorporando un micrófono junto con un comparador LM393, que permite leer tanto un valor analógico como uno digital. Además, en el exterior de la caja electrónica se encuentra un botón de pánico accesible para alertar al operador de un posible accidente y anular una falsa alarma(Rodríguez & Corchado, 2020). La Figura 3.7 se muestra el cinturón con el panel de visualización y los diferentes indicadores de los sensores.

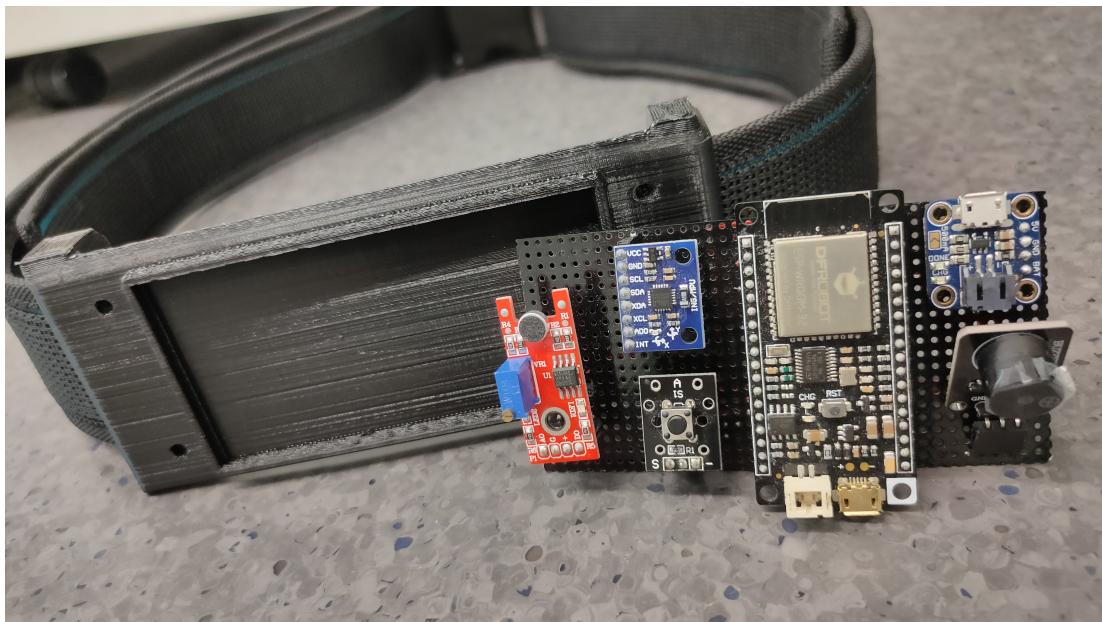


FIGURA 3.7: Diagrama de funcionamiento del firmware del brazalete.

En la siguiente Figura 3.8 se muestra el diagrama de flujo del firmware, con un sistema de reglas para la detección de alarmas en el hardware y a su vez la recogida y envío de datos de todos los sensores.

Cada uno de los dispositivos se compone de un módulo ESP32 (del fabricante chino Espressif) con comunicaciones Wi-Fi, integrando un firmware con reglas simples, con las que se permite alertar en tiempo real si algún valor ha superado el umbral límite. Una vez cada dispositivo ha recogido la información de los componentes encargados de monitorizar al trabajador y las condiciones del entorno, así como el porcentaje de energía de la batería de litio. Tras recoger la información, ésta se transmite vía Wi-Fi en formato de Notación de objetos de JavaScript (JavaScript Object Notation -JSON) al nodo Edge o un servidor local. Ya en este nodo, si se detecta una anomalía en primera instancia, la información se retransmite al sistema electrónico, siendo notificada con mayor rapidez,

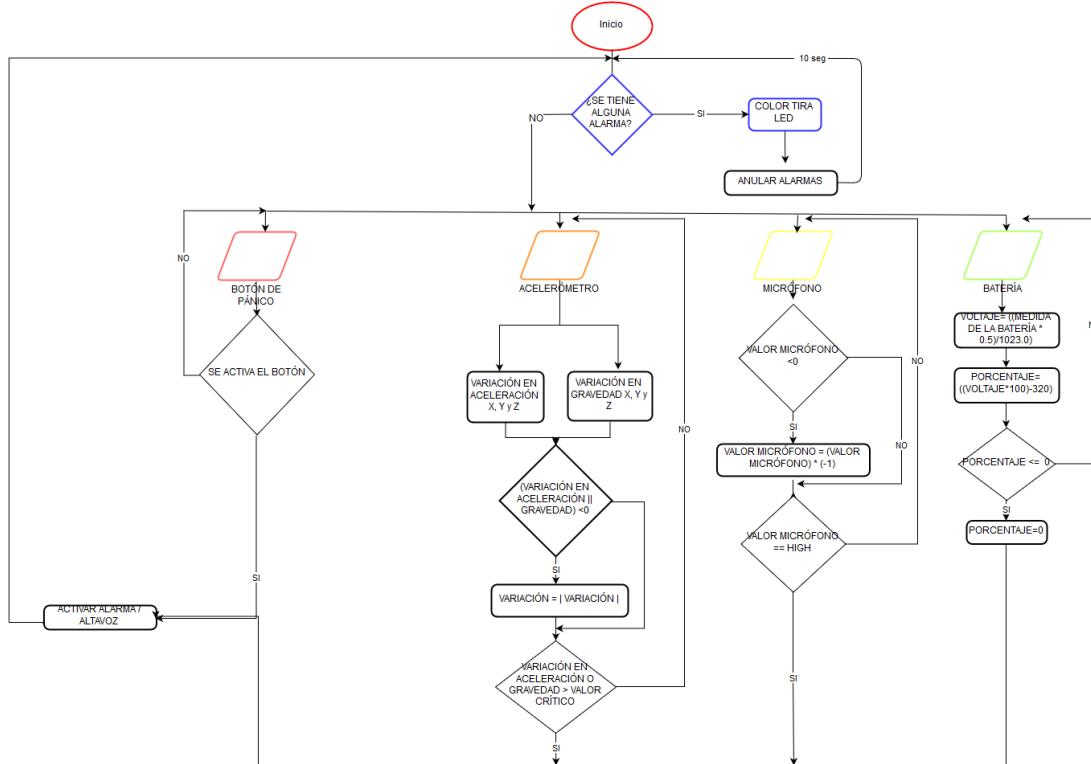


FIGURA 3.8: Diagrama de funcionamiento del firmware del brazalete.

que si tuviera que pasar por la capa Cloud y volver al dispositivo. La alimentación se realiza en todos los dispositivos mediante una batería Lipo de 3,7V, conectada al módulo de alimentación.

Hay que tener en cuenta que se repiten algunos sensores específicos integrados en los dispositivos, como es el caso de la Resistencia Cuadrada Sensible a la Fuerza (Force Sensitive Resistor - FSR), que colocada en el casco permite detectar si lo llevamos puesto y los impactos. Por otro lado, en el brazalete permite activar una alarma cuando se pulsa. También se repiten las IMUs en todos los dispositivos para medir caídas e impactos, utilizando la MPU6050 en el casco y el cinturón, y la BMI160 en el brazalete. Las ventajas derivadas de esta duplicidad es que tenemos más información para el entrenamiento y la detección de accidentes en la plataforma. Además, podremos tener la funcionalidad de lectura y detección de caídas utilizando los dispositivos por separado.

3.3.2. Edge Layer

El uso de Edge Computing permite incorporar nuevas soluciones verticales en las que realizar un preprocesamiento, eliminación del ruido, gestión de los datos razonada y

eficiente. Una vez recogidos los datos desde los dispositivos, la información puede ser procesada por el nodo Edge que proporciona respuestas personalizadas a los diferentes individuos en base a los datos recibidos de ellos. Estos nodos pueden actuar de forma autónoma, comunicándose con la plataforma de forma ad hoc cuando se requieran sus servicios e introducir capas de seguridad entre la plataforma y los nodos, lo que aumenta la fiabilidad de los datos. Además, gracias a las capacidades de procesar datos en bruto y extracción e integración de información, hace que con el conocimiento adquirido el nodo Edge comprenda la situación en la que se encuentra el operario y detecte las alertas de una forma mucho más eficaz(S. M. Sánchez et al., 2020).

Una de las principales características consideradas para el desarrollo de esta arquitectura es la modularidad, con el fin de permitir que este sistema sea escalable y reconfigurado de forma rápida y sencilla. En este sentido, el nodo Edge, actúa como Gateway permitiendo que los dispositivos puedan conectarse con el de forma alámbrica o inalámbrica a través de diversas tecnologías de comunicación (Bluetooth, Wi-Fi, LoRaWAN, Modbus, radiofrecuencia) y protocolos de comunicación como MQTT, Protocolo de transferencia de hipertexto (Hypertext Transfer Protocol - HTTP), todo dependiendo de las características de la aplicación y los dispositivos que la integren.

El para el procesamiento se utiliza una placa Single Board Computer (SBC) NanoPi, ideal como dispositivo de borde IoT por ser una potente placa de bajo consumo, que permite realizar cálculos intensivos de algoritmos basados en inteligencia artificial. El nodo Edge, se encarga de recoger los datos de diferentes dispositivos vía Wi-Fi en formato JSON. Posteriormente, realiza un procesamiento local de los datos recibidos. Por último, transmite posteriormente los datos más relevantes a través de la comunicación con el servidor Mosquitto con el protocolo de comunicación MQTT, reduciendo la tasa de envío a los datos esenciales. En este enfoque, los datos se envían a través de Internet (3G o 4G) desde el nodo Edge a la capa Cloud, permitiendo el almacenamiento, procesamiento y la visualización de los datos a través de una interfaz web.

Se ha llevado a cabo el diseño de la PCB según los requisitos funcionales especificados en la arquitectura final, donde la NanoPi NEO Core se encarga del procesamiento de datos y donde además se incluyen dentro del circuito los siguientes componentes principales:

- **Power Supply:** Se compone de un regulador de tensión 24VDC a 5VDC y de un regulador de tensión de 5VDC a 3,3VDC; así como de los bloques de terminales

escogidos como entrada y salida de alimentación. Los reguladores de tensión escogidos son los siguientes:

- **LMZ23605:** este integrado es un módulo de potencia step-down capaz de conducir hasta 5 amperios de carga con una gran eficiencia (84 % con 24V de entrada y 5A de carga). Puede aceptar de 6V a 36V de entrada (corriente continua) y ofrecer un voltaje de salida de 0.8V a 6V (regulados mediante el circuito de configuración).
- **XC6220B331MR-G:** es un regulador de voltaje de gran precisión capaz de conducir hasta 1A de carga para una tensión de salida entre 1.2V y 5V.
- **Wireless Communication:** El módulo de comunicaciones inalámbricas está integrado por el módem 3G/4G y por un módulo ESP32. El circuito del módem 3G/4G se compone de:
 - **MicroSIM:** conector para tarjeta microSIM. Los pines son conectados al módem 3G/4G salvo el de detección de tarjeta (DET_SIM), que ha sido conectado a la NanoPi.
 - **DALC208SC6:** diodos de protección para descargas electroestáticas (ESD) utilizado para proteger el conector de tarjeta SIM.
 - **Módem 3G/4G:** se ha escogido el módem Telit LE910 para dotar al dispositivo de una comunicación 3G/4G. Este módem utiliza un tipo de conector mPCIe, el cual conecta el módem tanto con la tarjeta SIM (pines VCC-SIM, DATA-SIM, CLK-SIM y RST-SIM) como con la NanoPi mediante conexión Universal Serial Bus (USB) (pines 3D-/3D+). También es controlada por la NanoPi mediante los pines PERST (para resetear) y W_Disable (para habilitar/deshabilitar el modo vuelo). Se ha dispuesto un LED azul para visualizar el estado de la comunicación WWAN.
 - **PRTR5V0U2X,215:** diodo de protección para descargas electroestáticas (ESD) diseñado específicamente para protección de líneas de datos de alta velocidad como los puertos USB 2.0

Se ha dispuesto un módulo ESP32 para dotar al dispositivo de una comunicación Wi-Fi/Bluetooth. Este módulo se comunica con la NanoPi mediante una comunicación serie (pines RX2/TX2).

■ **RS232-RS485:** El circuito se compone de 2 transceptores para comunicaciones RS-485, 1 transceptor de dos canales para comunicaciones RS-232, un conversor de nivel lógico para las comunicaciones y 4 multiplexores con los que poder escoger entre una comunicación RS-232 o una comunicación RS-485 mediante software. Los principales componentes son los siguientes:

- **MAX485CSA+:** Transceptor de RS485 de 1 canal. Posee resistencias del pullup y pulldown de 20K y 10K para fijar un nivel de tensión en reposo que pueda ser reconocido por el receptor. También incluye una resistencia de terminación de línea de 120 ohms para garantizar la impedancia en las líneas de comunicación, en el caso de que el receptor se sitúe a una distancia elevada. Los pines RE y DE son controlados por la línea TX/RX_EN. Sirve para establecer el modo de funcionamiento del transceptor (1 = Modo TX, 0 = Modo RX).
- **MAX3232CDR:** Transceptor de RS232 de 2 canales. Los condensadores externos permiten al integrado aumentar e invertir la tensión para la salida del bus RS232.
- **TMUX1136DGSR:** Es un conmutador de 2:1 (SPDT) con 2 canales independientes. Admite señales analógicas y digitales bidireccionales. Sirve para commutar las líneas de comunicación entre los transceptores de RS232 y RS485. La línea de control del conmutador es RS_SEL (1 = RS485, 0 = RS232).

■ **USB Ports.** El circuito de los dos puertos USB está integrado por:

- **TPS2080DR:** interruptor de alimentación dual con el que poder desconectar los puertos USB. Este componente es controlado por la NanoPi mediante el pin USB_EN. A nivel lógico bajo se habilita y a nivel lógico alto se deshabilita. Además, mediante el pin OC_USB, es capaz de advertir ante sobrecorrientes o condiciones de temperatura alta no deseada (nivel lógico bajo).
- **PRTR5V0U2X,215:** diodo de protección para descargas electroestáticas (ESD) diseñado específicamente para protección de líneas de datos de alta velocidad como los puertos USB 2.0.

- **Conectores USB:** conectores específicos USB. Las líneas de datos 1D+/1D- (USB1) y 2D+/2D- (USB2) son tomadas de las dos primeras salidas USB de la NanoPi.
- **Ethernet.** El circuito del puerto Ethernet se compone de:
 - **SP3002-04JTG:** diodos de protección para descargas electroestáticas (ESD) diseñado para protección de buses de transmisión de datos. La entrada de alimentación VCC se mantiene sin conexión tal y como indica el fabricante para el uso del integrado en puertos Ethernet.
 - **Conector Ethernet:** conector específico Ethernet. Las líneas de datos TRD1+/ TRD1-, TRD2+/ TRD2-, TRD3+/ TRD3-, TRD4+/ TRD4- son tomadas de los pines específicos de la NanoPi para comunicación Ethernet. Ofrece además dos LEDs para indicar el estado de la comunicación. Estos son controlados mediante los pines SPD-LED (para indicar la velocidad de comunicación) y LINK-LED (para indicar la conexión).
- **El circuito ADC** se compone de un módulo conversor Analógico/Digital se compone del circuito de acondicionamiento de señal tanto para sondas PT100/PT1000 y sensores con salidas analógicas 0-10V y 4-20 mA; un conversor A/D de 8 canales y un regulador de tensión para mantener una tensión estable en el conversor.
 - **MAX31865ATP+:** conversor de resistencia analógica a digital de 15 bits de resolución especialmente diseñado para conversión de valores de sondas de temperatura PT100/PT1000. Transmiten el valor de resistencia mediante comunicación SPI (pines SCLK, SDI, SDO). Se han dispuesto 2 integrados para poder tomar datos de dos sondas de temperatura PT. La comunicación con dichos integrados se establece mediante la habilitación del bus SPI configurando a nivel bajo los pines CS1/CS2. Solo se puede habilitar un integrado a la vez tal y como define el protocolo SPI. Mediante los pines DRDY, el integrado manda una interrupción a la NanoPi para avisar de que la conversión se ha realizado y está lista para ser leída.
 - **Sensores analógicos 0-10V:** Sensores analógicos 0-10V: se han dispuesto 4 entradas de sensores analógicos 0-10V. Este tipo de sensores transmiten la información mediante una señal de tensión que varía entre 0V y 10V. Dicha

señal pasa por un divisor de tensión antes de ser leída mediante el conversor analógico/digital.

- **Sensores analógicos 4-20mA:** se han dispuesto 4 entradas de sensores analógicos 4-20mA. Este tipo de sensores transmiten la información mediante un lazo de corriente que varía desde los 4 mA hasta los 20 mA. Para poder tomar el valor de tensión, se utiliza una resistencia de 120Ω entre la entrada (salida de señal del sensor) y GND. El valor de tensión es tomado mediante el conversor analógico/digital.
- **ADC128D818CIMTX/NOPB:** conversor A/D de 12 bits de resolución utilizado para medir las señales provenientes de los sensores analógicos. Este integrado se comunica con la NanoPi mediante un bus I2C (pines SCL, SDA). Posee un pin de interrupción para comunicar al procesador posibles errores en la lectura, si unos valores umbrales configurados se han sobrepasado, etc....
- **MAX6043BAUT50+T:** regulador de tensión utilizado para estabilizar la tensión de referencia del conversor A/D.

El diseño del circuito electrónico y la disposición en cuanto a conectores y puertos de los distintos sensores, periféricos y módulos que integran del dispositivo Edge se muestra en la siguiente Figura 3.9:

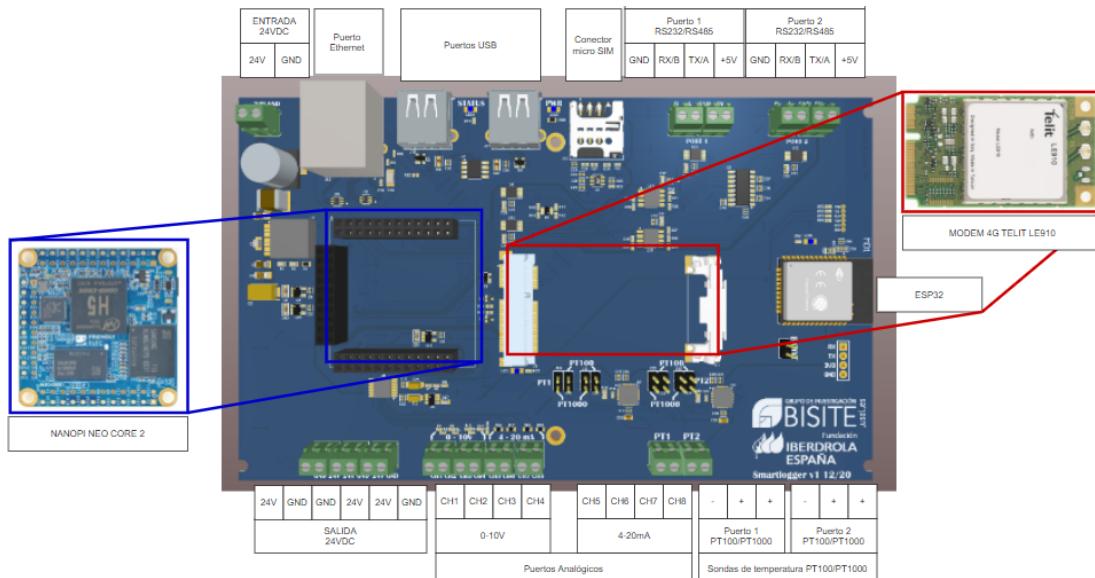


FIGURA 3.9: Diseño electrónico y disposición de los conectores y puertos.

Se llevo a cabo la fabricación de la placa donde el diseño electrónico vino definido por el esquema electrónico y tiene unas dimensiones marcadas por la carcasa escogida para contener toda la electrónica. A continuación, se definen cada una de las partes:

- **Entrada 24VDC:** terminal de bloques para conectar la salida de la fuente de alimentación externa de 24 voltios de corriente continua.
- **Salida 24VDC:** terminal de bloques para conectar los cables de alimentación de los distintos sensores cuya alimentación es de 24 voltios de corriente continua. Está compuesto de 3 terminales de 24V y 3 terminales de GND.
- **Puerto Ethernet:** compuesto por un conector RJ45.
- **Puertos USB:** conectores USB para conectar con posibles periféricos externos.
- **Conector micro SIM:** conector de micro SIM necesario para dar acceso a la red al Modem 4G.
- **LEDs de Alimentación y Auxiliar:** LED con el que poder indicar de forma visual el estado de la alimentación y un LED auxiliar a disposición del programador.
- **Puertos RS232/RS485:** terminal de bloques para conexión de periféricos con un tipo de comunicación RS232/RS485. Las líneas de datos están marcadas desde el punto de vista del dispositivo, es decir, al terminal RX del dispositivo le corresponde el TX del dispositivo que se conecte y al terminal TX del dispositivo le corresponde el RX del dispositivo.
- **Canales analógicos 0-10V y 4-20mA:** terminales de bloques para sensores analógicos que proporcionen una señal 0-10V y 4-20mA.
- **Puertos sondas PT100/PT1000:** terminales de bloques para sondas de temperatura PT100/PT1000. Están diseñados para sondas de hasta 3 terminales. Así pues, si en algún momento se desea cambiar de una sonda de tipo PT100 a una de tipo PT1000, o viceversa, los “jumpers del puerto en cuestión deben intercambiarse.

Una vez realizada la fabricación se ha comprobado la efectividad del módulo y se ha validado el funcionamiento del sistema en base a parámetros y métricas de eficiencia en

la extracción y análisis de la información. También se han validado las capacidades de cómputo del sistema en base a test de estrés y se ha realizado un análisis de la eficiencia y escalabilidad de la placa. En cuanto a su validación, se han definido los escenarios donde realizar las pruebas del sistema, que han permitido obtener una muestra representativa del rendimiento y desempeño del mismo. A continuación, en la Figura 3.10 se muestran la imagen con el acabado final del dispositivo.

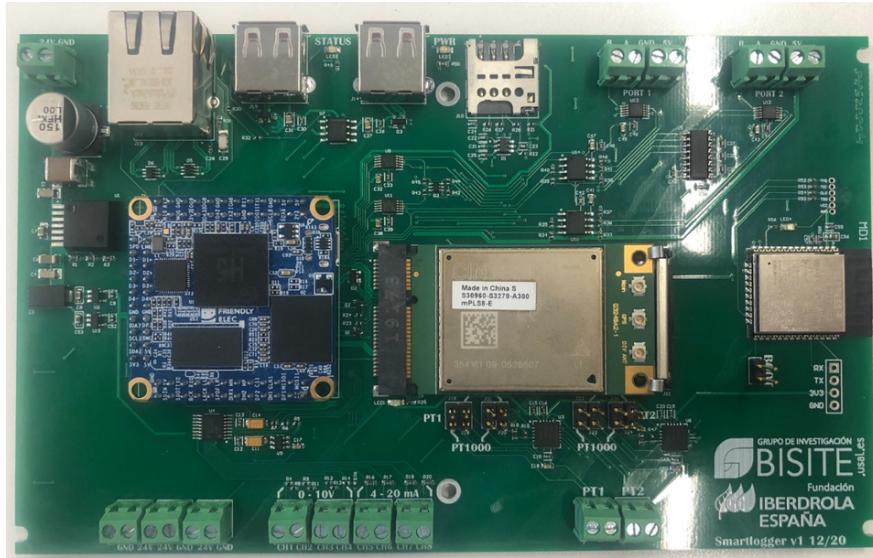


FIGURA 3.10: Placa fabricada con los módulos y electrónica Surface Mount Technology (SMD).

3.3.3. Server Layer

Las plataformas en la actualidad se centran en el aumento de la productividad, pero encontramos pocos ejemplos de plataformas que monitorean el entorno laboral y aseguren la integridad de los trabajadores. La mayor parte de estas plataformas se basan en modelos con estructuras de reglas, donde dependiendo de ciertas condiciones se pueden tomar decisiones sobre la información que se procesa en la nube. Sin embargo, la plataforma propuesta amplía estos desarrollos, integrando modelos de inteligencia artificial que trabajan conjuntamente para obtener un conocimiento exhaustivo de la situación incorporando sistemas cognitivos, como las Redes Neuronales Convolucionales (CNN) y el Aprendizaje de Refuerzo Profundo (DRL), lo que permite construir una herramienta capaz de controlar un enorme conjunto de parámetros relacionados con los trabajadores y el entorno.

De cara a la integración de los dispositivos de protección individual EPIs, para la detección temprana de anomalías, en la plataforma se contempla una capa Cloud que permita integrar algoritmos de fusión de información y minería de datos utilizando las capacidades de Smart Data para dar respuestas en tiempo real ofreciendo una base de conocimiento para la predicción de anomalías. Dentro de esta capa se integra además la capa de seguridad y el modelo de persistencia. La solución que se propone no renuncia a enriquecer la información que maneja con fuentes externas que suministren datos en tiempo real, pero el tratamiento que hace de ellos, sí que supone una revolución en tanto en cuanto los caracteriza y “traduce” para que el sistema pueda incorporarlos y trabajar con ellos dentro de sus bloques para el tratamiento inteligente de la información (Smart Data). Esto exige definir organizaciones especializadas en el Big Data para la Industria 4.0, que incorporen algoritmos de fusión de información (ya sea estructurada o no estructurada) y que permitan construir una base de conocimiento sobre la que predecir escenarios y caracterizar situaciones de riesgo. En este campo del procesamiento de la información destaca el uso de frameworks de uso libre (Hadoop, Spark...), que hacen factible la aplicación de procesos de minería de datos y algoritmos inteligentes, a datos procedentes de diversas fuentes, para construir un sistema Smart Data capaz de proporcionar respuestas inteligentes, para lo que se desarrollarán las estructuras y ontologías necesarias, que permitan describir la problemática a la que se enfrenta el sistema y dotarle de capacidad de “comprensión”.

El objetivo final es disponer de una plataforma completa donde los equipos de protección monitoricen zonas estratégicas del cuerpo, para reducir los tiempos de respuesta ante accidentes o problemas que puedan producirse durante la jornada de trabajo. Para ello, una vez que los datos han llegado a la capa Cloud se realiza el apilamiento de modelos ML y modelos Deep, mediante la representación de la información como un grafo complejo. Esto nos permite manejar información con comportamiento no lineal de una forma natural, donde, al final, estamos obteniendo una votación de la información.

Como se ha mencionado en la introducción, se han desarrollado diferentes dispositivos, con el objetivo de que se puedan utilizar para garantizar la seguridad de los trabajadores en entornos hostiles. Una vez que estos datos llegan a la capa Cloud, se han implementado una serie de algoritmos para trabajar con el conjunto de datos, para lo cual se ha incorporado un sistema de Smart Data capaz de dar respuestas inteligentes, integrando algoritmos de fusión, procesos de minería de datos de los diferentes dispositivos

conectados y una base de conocimiento que reduce la repercusión e impacto de las anomalías. Otra de las características que incorpora esta capa, es la capacidad de que el usuario pueda explotar todos los resultados con cuadros de mando dinámicos, reutilizables, que pueda compartir y utilizar dentro de otras herramientas de las que disponga en su empresa.

A continuación en la Figura 3.11 se muestra los diferentes paneles de visualización creados por cada uno de los dispositivos, donde podemos visualizar las alarmas detectadas.



FIGURA 3.11: Panel de selección de dispositivo.

En el caso del casco, se permite visualizar luminosidad, calidad de aire, temperatura, humedad y los impactos, tal y como se muestra en la siguiente Figura 3.12.

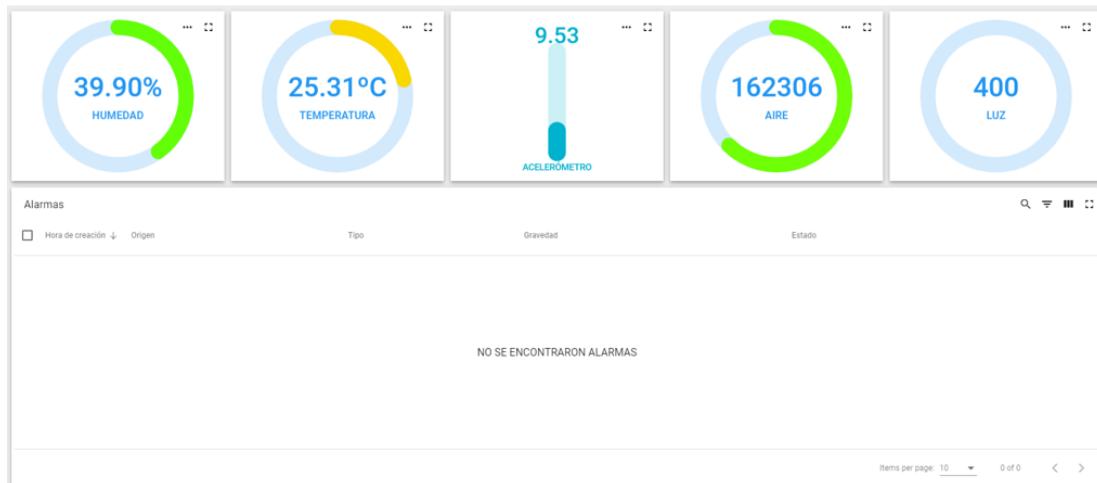


FIGURA 3.12: Panel de visualización de datos casco.

Para el brazalete, tendremos la opción de ver el ritmo cardíaco, temperatura corporal y el nivel de batería del dispositivo, tal y como se ve en la Figura 3.13.

Por último, para el cinturón se muestra un indicador de caídas, visualización de la aceleración en cada eje y la fuerza G detectada, así como el nivel de ruido, batería y un indicador de botón de pánico activado o no, Figura 3.14.

Con la integración dentro de la plataforma de la capa Cloud se ha permitido integrar conjuntos de datos provenientes de diferentes fuentes, priorizando los datos más



FIGURA 3.13: Panel de visualización de datos brazalete.

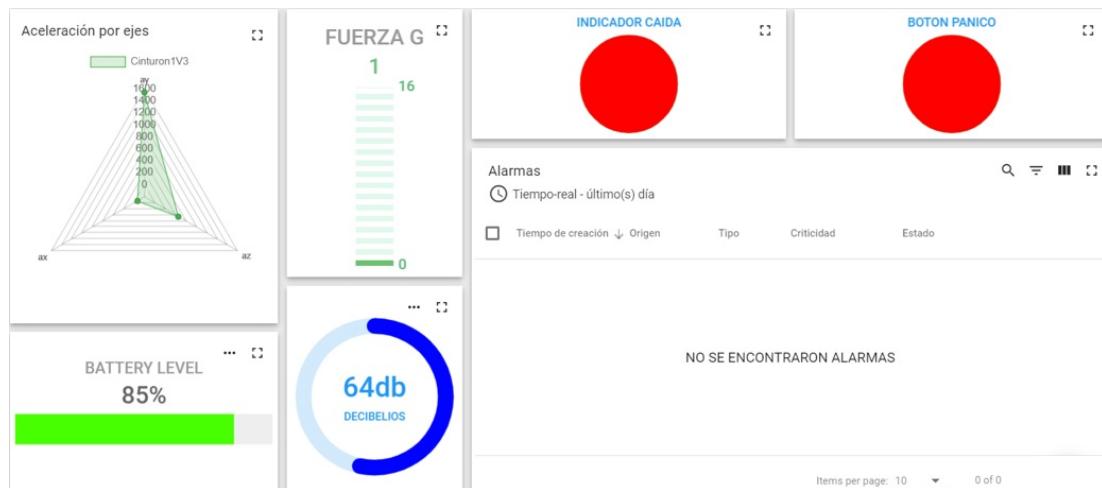


FIGURA 3.14: Panel de visualización de datos cinturón.

relevantes, debido a la posibilidad de enviar y almacenar datos provenientes de las capas inferiores en los diferentes formatos: ficheros formateados (CSV/JSON) tanto locales como disponibles en la plataforma, bases de datos (NoSQL y SQL), datos en streaming (MQTT, entre otros), etc. En cuanto al desarrollo del análisis de datos, se han aplicado tecnologías que permiten la detección automática del tipo de datos para facilitar el análisis y la representación. Además se ofrecen mecanismos para el tratamiento de datos (filtrar registros según un criterio, eliminar campos, fusionar fuentes, crear campos compuestos, etc.). Esto se debe al diseño modular que permite la obtención de datos de diferentes fuentes o dispositivos en el futuro, utilizando la misma infraestructura. También esta capa permitirá ofrecer mecanismos que faciliten la representación de la información proporcionada por el usuario, creando dashboard para los diferentes dispositivos y módulos dentro del sistema. Por último, se pueden exportar resultados

en periodos históricos para poder ser fácilmente integrados en informes. etc.

Machine Learning, se define como un proceso automático para extraer patrones de conjuntos de datos. Para construir modelos predictivos usados en aplicaciones de análisis de datos se usa aprendizaje supervisado, estas técnicas aprenden de manera irreflexiva un modelo de relaciones entre un conjunto de características descriptivas (continuas o categóricas) y características objetivo (conocidas como target o label) basados en un conjunto de datos históricos, logrando hacer predicciones para nuevas instancias o entradas véase la próxima Figura 3.15 en donde se ejemplifica lo mencionado.

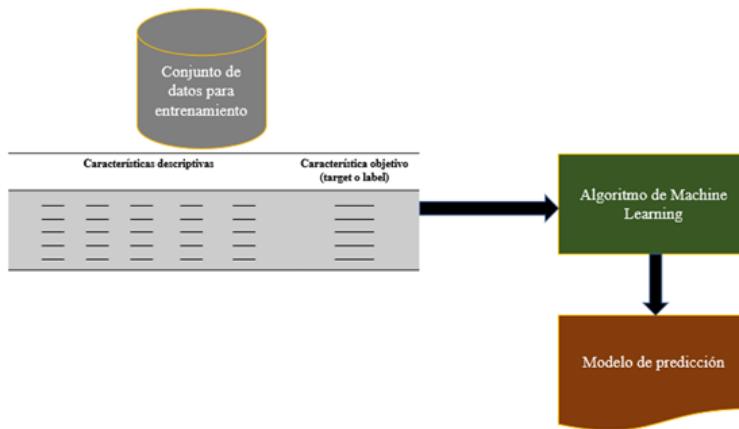


FIGURA 3.15: Estructura de un proceso Machine Learning.

Los algoritmos de machine learning automatizan el proceso de aprendizaje de un modelo que captura la relación entre la característica descriptiva y la objetivo.

Los algoritmos de aprendizaje automático funcionan buscando a través de un conjunto de posibles predicciones para generar el modelo que capture mejor la relación entre las características descriptivas y un conjunto de datos, para ello, considerar lo siguiente:

- Cuando los conjuntos de datos son muy extensos es muy probable que exista ruido, por lo tanto, esto generará problemas en el tiempo de predecir.
- En muchos algoritmos de aprendizaje automático el conjunto de formación significa sólo una pequeña muestra del posible conjunto de instancias del dominio. Como resultado, el aprendizaje automático es un problema mal planteado. Un problema mal planteado es un problema para el cual una solución única no puede determinarse utilizando sólo la información disponible.

Todos los diferentes criterios de selección de modelos consisten en un conjunto de suposiciones sobre las características del modelo.

3.4. Casos de estudio

La aplicación de tecnologías de información y la comunicación (TICs) en la salud y seguridad en el trabajo han proporcionado avances en monitoreo y cuidado del trabajador en su entorno, generando Equipos de Protección Individual (EPI) con capacidad de tomar decisiones basadas en las observaciones de su entorno a fin de reducir la tasa de accidentes en espacios laborales. Actualmente la inteligencia artificial tiene un impacto extraordinario sobre distintas disciplinas entre las cuales destaca la PRL. Para proveer de protección en el ámbito y después definir las diferentes capas de la plataforma, el presente punto se presenta los casos de estudio realizados con los tres dispositivos diseñados: casco de seguridad, cinturón y brazalete. En donde cada uno ha sido optimizado a través de técnicas de inteligencia artificial para asegurar una correcta toma de decisiones. En la Figura 3.16 se puede observar a un operario con los dispositivos citados colocados.

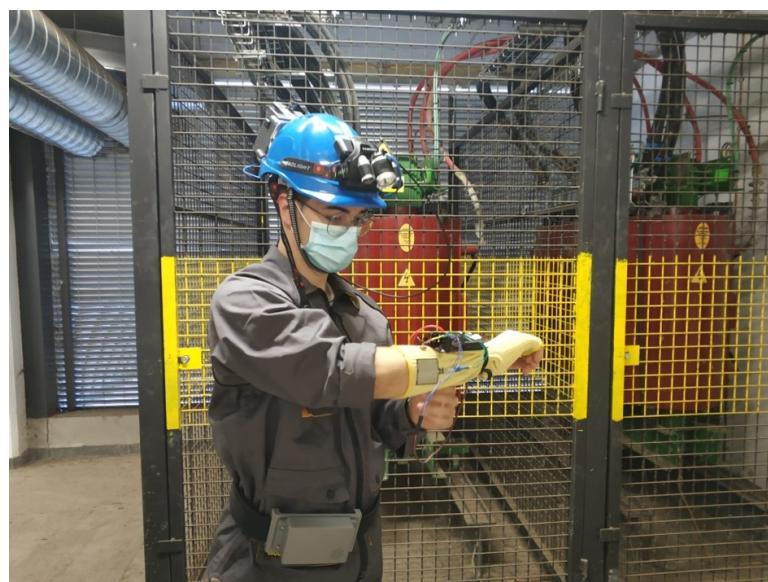


FIGURA 3.16: Fotografía de un operario con los dispositivos colocados.

Los datos obtenidos a través de los dispositivos son procesados posteriormente por un modelo inteligente, el modelo confirma o niega la existencia de una emergencia real. Esta es la razón por la que la configuración de la plataforma es muy importante.

Se han creado para ello una asociación entre los diferentes valores de los sensores y la respuesta correspondiente. Una vez creadas estas asociaciones, es posible modificar cualquier valor en función de los valores a comprobar empíricamente o en las alarmas. Las alarmas se configuran en los ajustes del dispositivo para que aparezcan las respectivas notificaciones en el panel, añadiendo una cadena de reglas.

Se ha realizado por último una selección de los atributos colocados en el servidor y en el panel de umbrales del dispositivo. Los nombres de los atributos en el servidor se corresponden con los del panel para que, al configurarse dinámicamente los datos, se reconozcan correctamente y aparezcan en el diagrama generado por la plataforma.

Se han incorporado diferentes algoritmos incluidos en el estado del arte, donde se utilizan para resolver problemas similares o relacionados con el que aquí se aborda. Estos modelos han sido aceptados para problemas del mundo real, realizando una comparación de cada uno de ellos sobre una base cuantitativa objetiva, que a continuación se describe para cada uno de los dispositivos en detalle.

En concreto para su evaluación, en el caso del casco inteligente multisensorial se implementó una Red Neural Convolucional Profunda (ConvNet/CNN), en el caso del cinturón se integraron los datos alineados por el modelo de Naïve Bayes, y para el brazalete un modelo híbrido de una Red Neural de memoria a corto plazo y un Modelo de Mezcla Gaussiana. Además, la plataforma final hace una comparativa de los diferentes modelos de inteligencia artificial, sacando diferentes conclusiones, tal y como se extiende en los siguientes puntos.

3.4.1. Casco inteligente

El casco inteligente descrito en (Campero-Jurado et al., 2020) es un equipo de seguridad en el que se realizó una comparación de diferentes modelos de Machine Learning para encontrar uno adaptable al análisis del comportamiento de la actividad humana. En este estudio se han obtenido muestras de datos de un entorno real, en el que se ha sometido a un sujeto a diversos escenarios en entornos simulados, considerando los diferentes riesgos que podrían surgir. Se proponen cinco variantes descriptivas respecto al objetivo del estudio:

- Brillo

- Variación en los ejes X , Y y Z
- Resistencia sensible a la fuerza
- Temperatura, humedad y presión
- Calidad del aire

Esta investigación aborda un problema de tipo multiclasificación, por esta razón hay un conjunto de etiquetas que tienen un significado diferente. Cuando se realizó la programación del dispositivo, se investigaron los diferentes valores de los parámetros que podrían activar una señal de alarma, por ejemplo, si la calidad del aire cae por debajo del umbral (medido por el Índice de Calidad del Aire, ICA o Air Quality Index, AQI) es posible asociar esta situación con los valores de otros parámetros medidos por los sensores vecinos. Una vez comprendida la información, se limpia.

Para el casco inteligente desarrollado, se clasificaron 12 clases o etiquetas, elegidas según los valores atípicos para cada uno datos recogidos por los 5 sensores en combinación, con el objetivo de actuar de forma rápida cuando se detecte una anomalía. A continuación se describe cada una de ellas:

- Calidad de aire buena (AQI de 0 a 50) con suficiente iluminación en el entorno de trabajo.
- Calidad del aire moderada (AQI de 51 a 100) con ligeras variaciones de temperatura y humedad.
- Calidad del aire perjudicial para la salud de los grupos sensibles (AQI de 101 a 150) con una variación moderada de la temperatura y la humedad.
- Calidad de aire perjudicial para la salud (AQI 151 a 200) con una variación considerable de la temperatura y la humedad.
- Calidad de aire muy perjudicial para la salud (AQI 201 a 300) con una variación elevada de la temperatura y la humedad.
- Calidad de aire peligroso (AQI superior a 300) con variación atípica de la temperatura y la humedad.
- Falta de iluminación y variación equivalente a una caída en el acelerómetro.

- Falta de iluminación, variación equivalente a una caída en el acelerómetro y una fuerza considerable ejercida sobre el casco.
- Variación atípica en el acelerómetro y fuerza moderada detectada en el FSR.
- Problemas de iluminación, calidad del aire y variación brusca en el acelerómetro.
- Fuerza muy alta ejercida sobre el FSR.
- Variación en el acelerómetro con problemas de iluminación.

El conjunto de datos adquiridos consta de un total de 11.755 muestras, de los cuales el 80 % se utilizó para el modelado y el 20 % para la evaluación cruzada, es decir, 9.404 en el entrenamiento y 2.351 en la evaluación. Cabe mencionar que todos los modelos fueron entrenados y validados con la misma división de datos en relación 80-20, también es notable sobresaltar un desbalance de clases, donde algunos modelos tuvieron un comportamiento desfavorable en la validación cruzada. Para arreglar este hecho, se ha optado por el uso de técnicas como el sobremuestreo o el submuestreo, pero debido a que no se desea cambiar la calidad de los datos, se eligió el modelo con mejor desempeño y se evaluó con 10 pliegues para la validación. En la comparación de los modelos Machine Learning , se utilizó la máquina de vectores de apoyo, el clasificador Naïve Bayes, una red neuronal estática y una red neuronal convolucional.

Después de la comparación de los modelos, finalmente el mejor rendimiento fue para la Red Neural Convolutacional Profunda (CNN) con un 92,05 % de media para todas las clases (representadas con diferentes colores). Esta se basa en un algoritmo de aprendizaje profundo y se utiliza principalmente para trabajar con imágenes. Se caracteriza por la posibilidad de utilizar una imagen de entrada (en lugar de un único vector como en las Red neuronal estática NNs), a la cual se le asigna importancia, pesos, sesgos aprendibles a varios aspectos/objetos de la imagen, y de esta forma se puede diferenciar unos de otros (Kalchbrenner, Grefenstette, & Blunsom, 2014). La ventaja de las NN es su capacidad de aprender estos filtros/características.

El funcionamiento de la CNN propuesta se ilustra en la Figura 3.17. La CNN consiste en segmentar grupos de píxeles cercanos a la imagen de entrada y operar matemáticamente contra una pequeña matriz llamada kernel. Una CNN puede contener las características de dependencia espacial y temporal en una imagen aplicando los filtros pertinentes, lo

mismo ocurre con un conjunto de datos que ha sido reorganizado. El modelo propuesto es una capa de entrada para el vector transformado de tamaño $5 \times 1 \times 1$ con dos capas convolucionales ocultas para datos bidimensionales (Conv2D) y funciones de activación ReLU con un total de 64 y 32 neuronas respectivamente. Por último, una capa con 12 neuronas de salida con función de activación SoftMax para la clasificación multiclas. Con ese tamaño se consigue visualizar todas las neuronas de entrada y así puede generar una nueva matriz de salida, matriz que será nuestra nueva capa de neuronas ocultas.

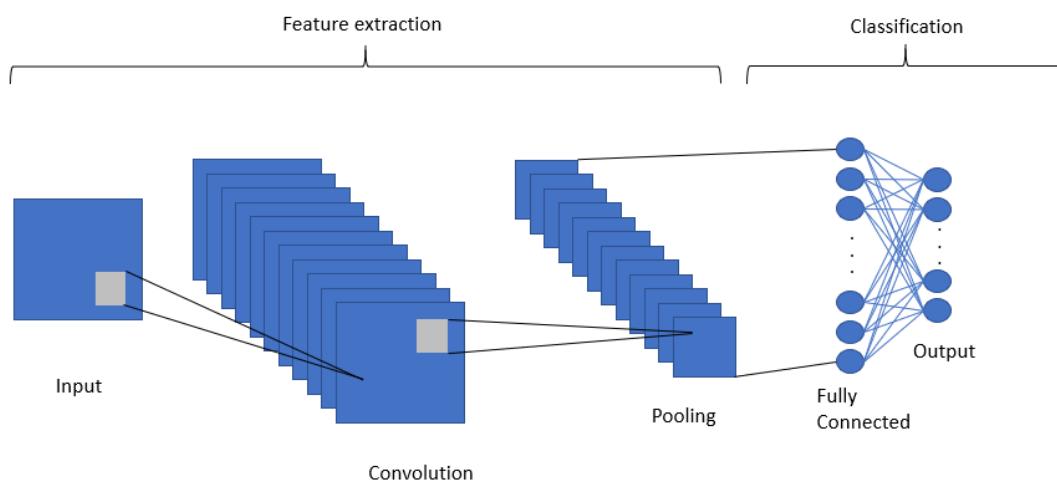


FIGURA 3.17: Red neuronal convolucional profunda operación.

Se propuso un modelo clásico de Adam y se entrenó con 500 períodos, los parámetros fueron los mismos para la NN estática y la CNN para tener un margen objetivo respecto a su evaluación. A continuación, se muestran los resultados de los modelos de IA utilizados para su implementación en el casco multisensorial. La tabla 3.1 muestra la evaluación de la CNN donde se alcanzó como comentábamos anteriormente la mejor precisión global, con un valor de 92,05 %.

TABLA 3.1: Confusion matrix SVM.

Predicted Class (Vertical)/ True Class (Horizontal)	Class 0	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6	Class 7	Class 8	Class 9	Class 10	Class 11
Class 0	153	10	31	0	0	0	0	0	0	1	1	6
Class 1	0	122	0	0	1	6	0	12	0	2	1	5
Class 2	20	0	192	0	0	0	0	0	0	120	0	0
Class 3	20	0	0	158	3	0	13	25	2	101	0	7
Class 4	1	0	0	0	12	0	0	0	3	5	9	0
Class 5	0	25	23	0	0	135	0	0	0	2	8	7
Class 6	0	0	0	0	0	0	110	30	0	1	0	0
Class 7	15	5	30	0	0	57	0	159	0	5	0	0
Class 8	1	9	0	30	0	0	20	0	11	1	0	9
Class 9	13	0	5	40	0	0	10	0	0	432	0	0
Class 10	0	8	0	4	0	0	0	6	0	3	53	0
Class 11	0	0	0	0	0	0	8	0	0	2	5	72

El SVM presentó una precisión general del 68,51 % que fue el modelo con menor rendimiento en la validación cruzada. Su comportamiento se compara con el del resto

de las clases analizadas en la Figura 3.18. Por lo tanto, se ha descartado el uso de este modelo en el casco multisensorial.

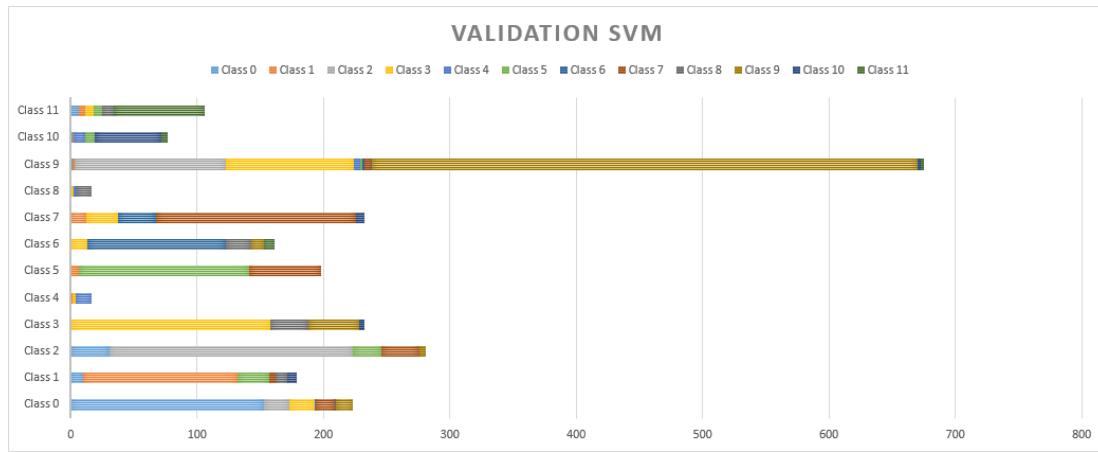


FIGURA 3.18: Resultados de la validación cruzada con el 20 % para el SVM.

NB ha logrado una precisión media del 78,26 % en todas las clases, como se muestra en la Figura 3.19. Su rendimiento ha sido mejor en las clases 5 y 11. A pesar de tener un mejor resultado que SVM se ha descartado ya que había modelos con mejor rendimiento.

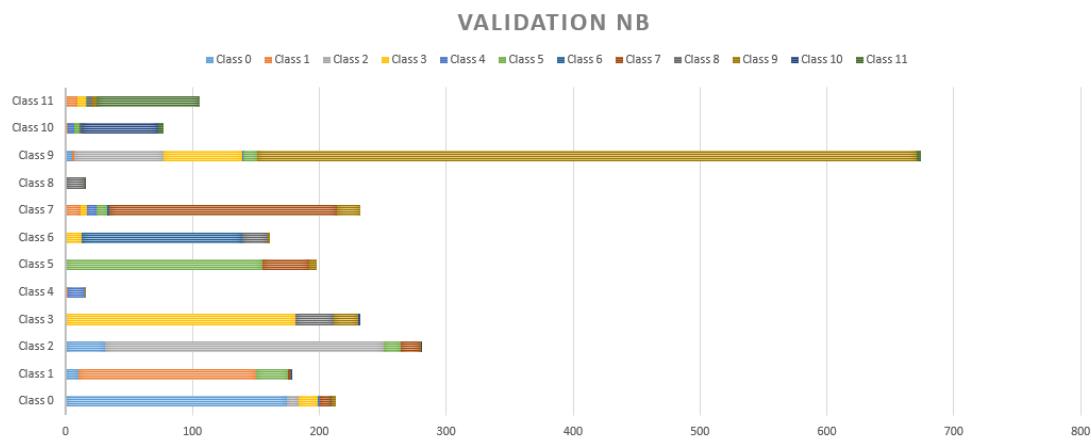


FIGURA 3.19: Resultados de la validación cruzada con el 20 % para el NB.

Las Figuras 3.20 y 3.21 muestran el rendimiento de la NN estática y la CNN respectivamente. En la Figura 3.19 se puede observar que no hay una diferencia significativa en el rendimiento de la NB en comparación con la NN, que tuvo una precisión del 78,56 %. Por el contrario, la CNN, con una precisión del 92,05 % tuvo un resultado considerablemente mejor, ya que este modelo permite la extracción implícita de características y el mantenimiento de las relaciones entre la información relativa al conjunto de datos.

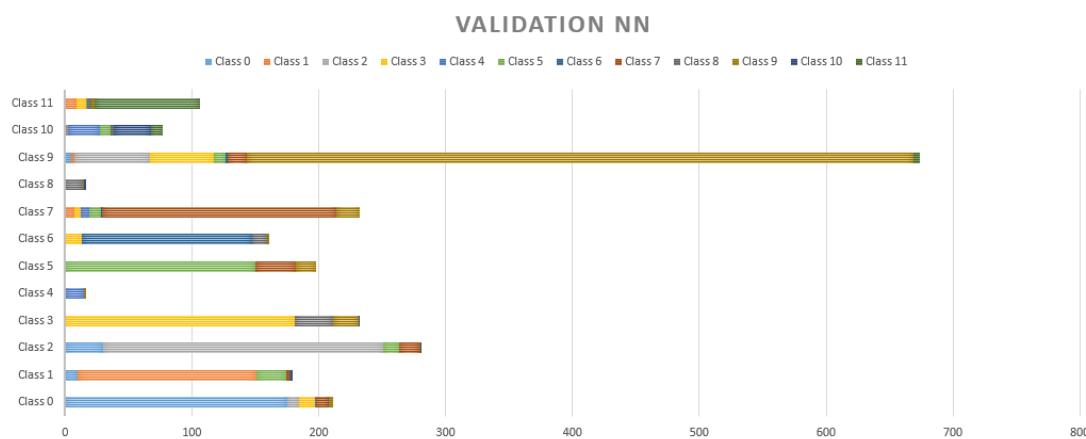


FIGURA 3.20: Resultados de la validación cruzada con el 20 % para el NN.

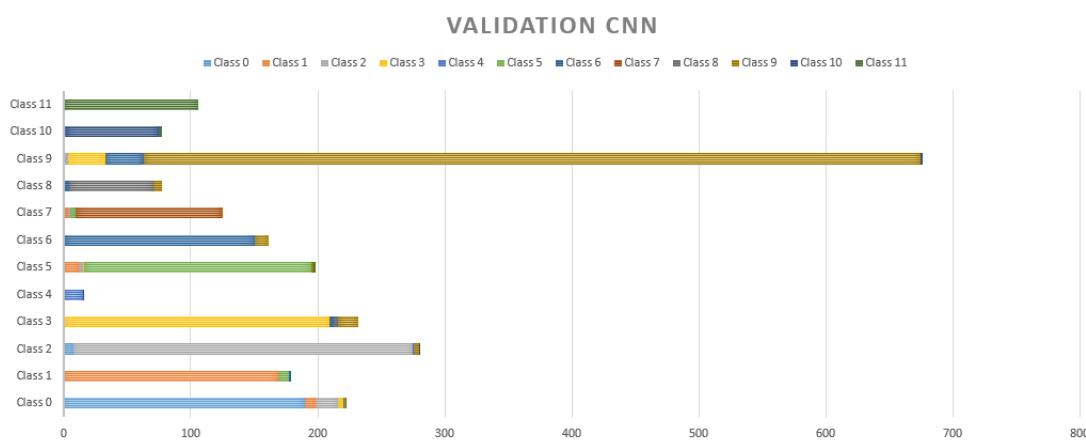


FIGURA 3.21: Resultados de la validación cruzada con el 20 % para el CNN.

Teniendo en cuenta lo anterior, CNN es el modelo que se ha implementado en la plataforma, encargándose de validar la información obtenida. Ambos trabajan de forma independiente, creando un sistema de alarmas en un entorno simulado que puede servir como sistema de soporte para generar un entorno más seguro en el trabajo. Anteriormente se mencionó que la creación de los modelos profundos fue a través del enfoque de “prueba y error”, pero no se debe dejar de lado el posible problema de overfitting, es por ello que en la Tabla 3.2 se muestran los resultados para la CNN en 10 Pliegues, donde se muestra el desempeño promedio desde un punto de vista objetivo de los modelos.

Los resultados de la valoración del modelo CNN fueron reestructurados según se muestra en la Figura 3.22, donde se muestran los diferentes clases y sensores que se analizaron para la detección de las posibles situaciones en las que el trabajador estaba sometido a las determinadas condiciones. Donde las diferentes circunstancias posibles que van desde

TABLA 3.2: Validación de diez veces para CNN.

Ten Fold Cross-Validation Test Sets	Accuracy (%) (Automated Risk Situations Develop in This Research)
1	93.18
2	93.09
3	90.73
4	94.12
5	91.27
6	92.75
7	92.61
8	92.59
9	92.76
10	91.99
Average Accuracy	92.509

tener un ambiente propicio para el trabajo (como buena calidad del aire, iluminación suficiente), hasta tener un riesgo estructural o físico (como detección de caídas a través de la CNN, falta de iluminación, ambiente comprometido por gases nocivos, etc.). Teniendo por objetivo en su combinación con la plataforma, la reducción de los tiempos de reacción en caso de accidente o percance.

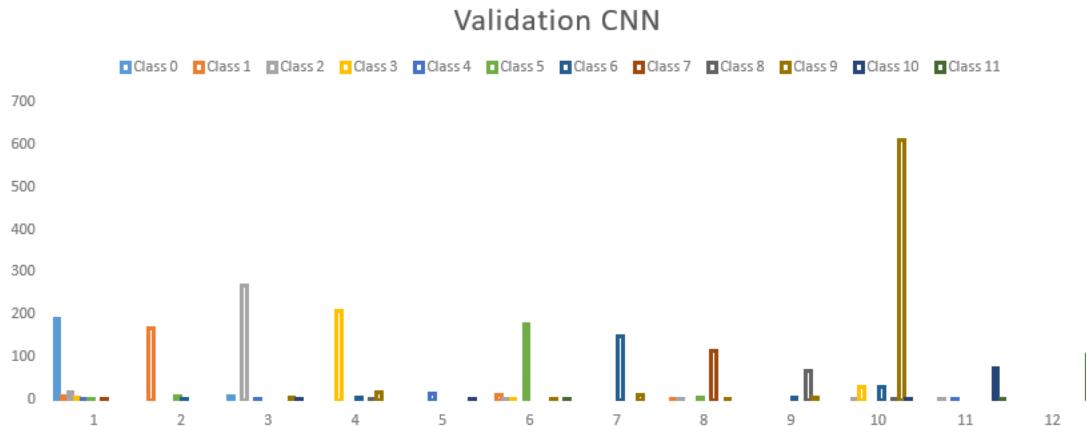


FIGURA 3.22: Resultados de la validación cruzada con el 20 % para el CNN.

A continuación, se muestran algunas imágenes del casco en su validación. En concreto en la Figura 3.23 podemos ver el casco con la alerta de haber alcanzado un nivel de gases crítico por encima del umbral límite, activando por tanto una alarma (de ahí que todos los leds se encuentren encendidos en verde, que es el color correspondiente a la alarma de gases). Debido a la baja luminosidad del ambiente en ese lugar y momento, la linterna también encuentra encendida, ofreciendo la luz necesaria para realizar las correspondientes tareas.

A medida que se reestablecen los valores nominales del lugar, el nivel de alarma (en este caso de gases) va disminuyendo. En la Figura 3.24, vemos como solamente se encuentra

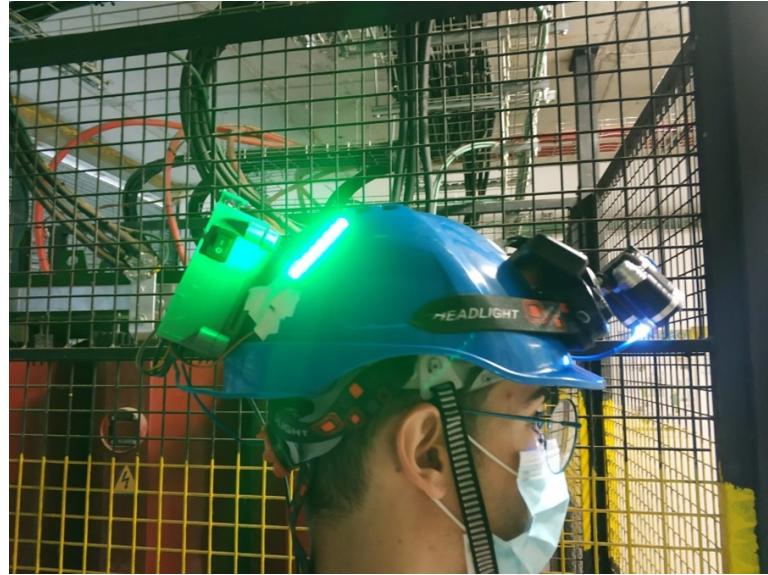


FIGURA 3.23: Casco en la evaluación en un centro de transformación con alarma de gases activada.

activado uno de los leds, encontrándonos en un nivel leve de alerta dentro del rango previamente configurado entre los valores umbrales.



FIGURA 3.24: Casco en la evaluación en un centro de transformación con alarma leve de gases activada.

Por último, en la Figura 3.25 se muestra el panel de la plataforma, en donde se muestran algunas de las alarmas recogidas durante las pruebas en un centro de transformación. Al haber alcanzado y sobrepasado los umbrales de los diferentes parámetros correspondientes, se han activados las alarmas relativas a estos, quedando

registradas y almacenadas en la base de datos. Pudiendo a su vez representarlas y tratarlas del modo más conveniente.

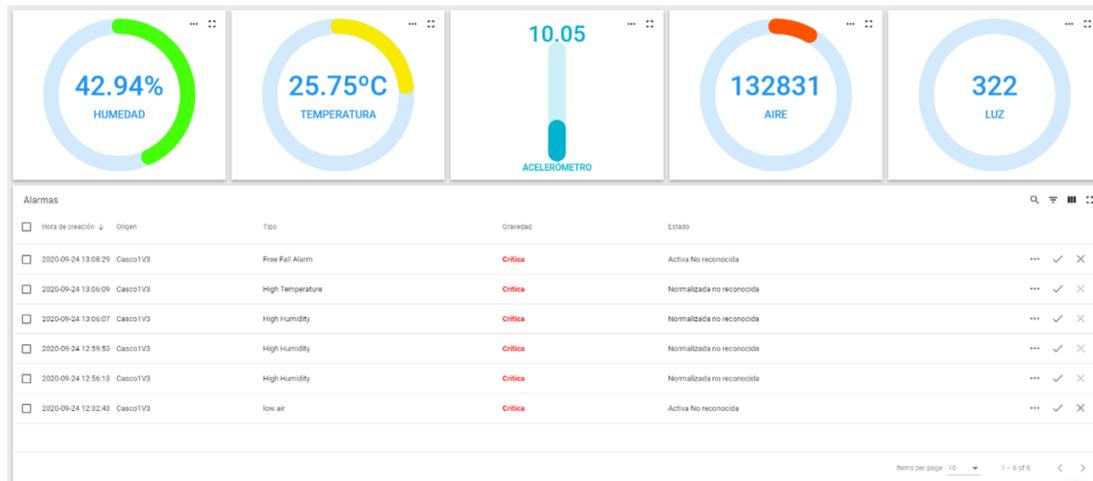


FIGURA 3.25: Panel de visualización del casco.

3.4.2. Brazalete inteligente

El brazalete inteligente es un dispositivo diseñado para ser llevado en la mano del usuario (Márquez-Sánchez, Campero-Jurado, Robles-Camarillo, et al., 2021). En este, las entradas del modelo son la temperatura corporal del usuario, su ritmo cardíaco y una variable que indica el estado del brazalete, es decir, el estado óptimo que viene dado por la batería y el acoplamiento físico. Se ha asignado una etiqueta entre 4 situaciones en un entorno real de trabajo, como una alerta de infarto por una perturbación, una caída, etc. Los problemas que se han registrado se engloban en:

- Ataque al corazón y latidos irregulares.
- Cambios extremos de temperatura que provocan un golpe de calor.
- Temperatura insalubre para el trabajador.
- Resbalones, tropiezos y caídas.
- Golpes en la mano del trabajador.
- Notificación de un accidente.

Se ha analizado la información realizando diferentes segmentaciones para el conjunto de datos. Posteriormente se han utilizado dos modelos de análisis de datos: un Modelo

de Mezclas Gaussianas enfocado en el análisis de las constantes vitales del trabajador y estado del brazalete. Y por otro lado una red neuronal Long Short Term Memory (LSTM), utilizada para analizar el comportamiento de la actividad humana. Estos datos se analizan por separado para reducir el ruido que puede originar la combinación de ambos modelos y así generar un sistema con un análisis híbrido en series temporales de anomalías, tal y como se puede ver en la Figura 3.26.

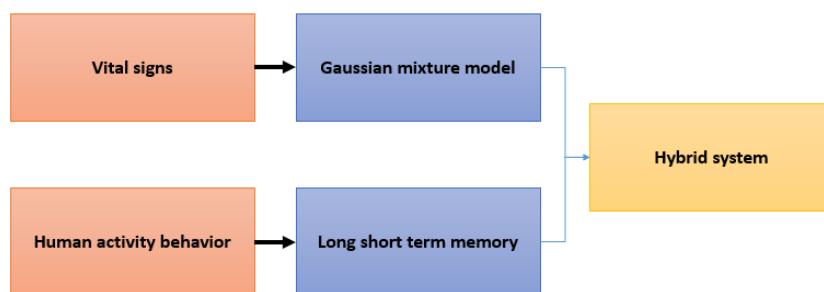


FIGURA 3.26: Análisis de datos mediante la unión de un modelo basado en anomalías y otro basado en series temporales.

El Modelo de Mezcla Gaussiana se utiliza como herramienta para agrupar la información en función de sus características, y entre sus ventajas, nos permite elegir los componentes de forma automática. A partir del estado del arte para el modelo presentado, podemos describir la base matemática del GMM como la densidad de probabilidad paramétrica representada como una suma gaussiana ponderada de las densidades de los componentes, donde los parámetros se estiman a partir de los datos de entrenamiento, mediante el algoritmo iterativo de maximización de expectativas (Expectation-Maximization - EM) o la estimación máxima a posteriori (Maximum A Posteriori Estimation - MAP).

A continuación, en la siguiente Figura 3.27 se muestran los resultados del GMM en tiempo real para 4 clases diferentes, con un rendimiento medio en tiempo real del 78,75 %. En ella podemos definir las etiquetas como: trabajador con constantes vitales estables y entorno no hostil, con el nombre de Stable Vital Sign and Non-Hostile Environment - SVSNHE, trabajador con variación suave de las constantes vitales, Smooth Variation in Vital Signs - SVVS, trabajador con constantes vitales en peligro y entorno no hostil, SVDNHE y trabajador en peligro por entorno hostil, (Danger due to Hostile Environment – DHE).

El segundo modelo es la red neuronal Long Short Term Memory (LSTM), utilizada para analizar el comportamiento de la actividad humana, utilizando también el modelo para

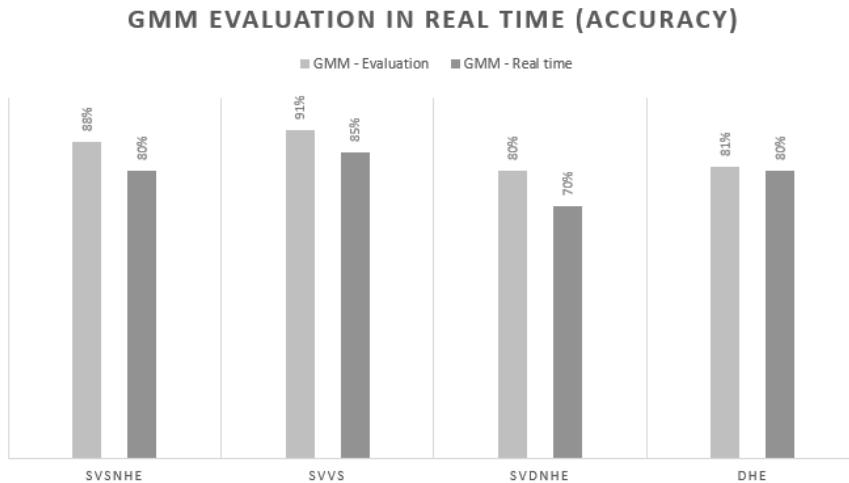


FIGURA 3.27: Resultados del GMM en tiempo real.

analizar los datos procedentes del sensor inercial IMU.

Como es bien sabido, existen modelos propuestos específicamente para el análisis de series temporales, en nuestro caso hacemos uso de uno de los más utilizados en la literatura por su robustez. Este es denominado LSTM y se trata de un modelo enfocado al recuerdo de información basado en redes neuronales recurrentes (Sundermeyer, Schlueter, & Ney, 2012). En el área del Comportamiento de la Actividad Humana (HAR) se estudian diferentes situaciones para tratar de encontrar una relación en el tiempo con el objetivo de modelar diferentes circunstancias. La investigación se centra en el ámbito industrial por lo tanto, hablando con expertos en esta área y realizando un análisis cuantitativo de las actividades más comunes se encontró que son: cargar-deslizar objetos, caminar-pararse y el análisis de caídas.

En la Figura 3.28 se muestra la matriz de confusión LSTM para los resultados obtenidos para el LSTM y GMM respectivamente, ya que el GMM por sí mismo no tenía un nivel de generalización suficiente. Se puede observar que el mejor rendimiento fuera para la clase WalkingScaling con un 96,14 %, para Falls el resultado fue del 89,2 % y el 77,06 % para Carrying, cuya clase es la más difícil de predecir para nuestro conjunto de datos.

En la Figura 3.29 se muestra el brazalete incorporado en el operario durante labores de su trabajo, en la cual vemos una alarma correspondiente a un pulso cardíaco anómalo provocado bajo condiciones controladas para la realización de las pruebas, con las que verificar la correcta activación de las alarmas.

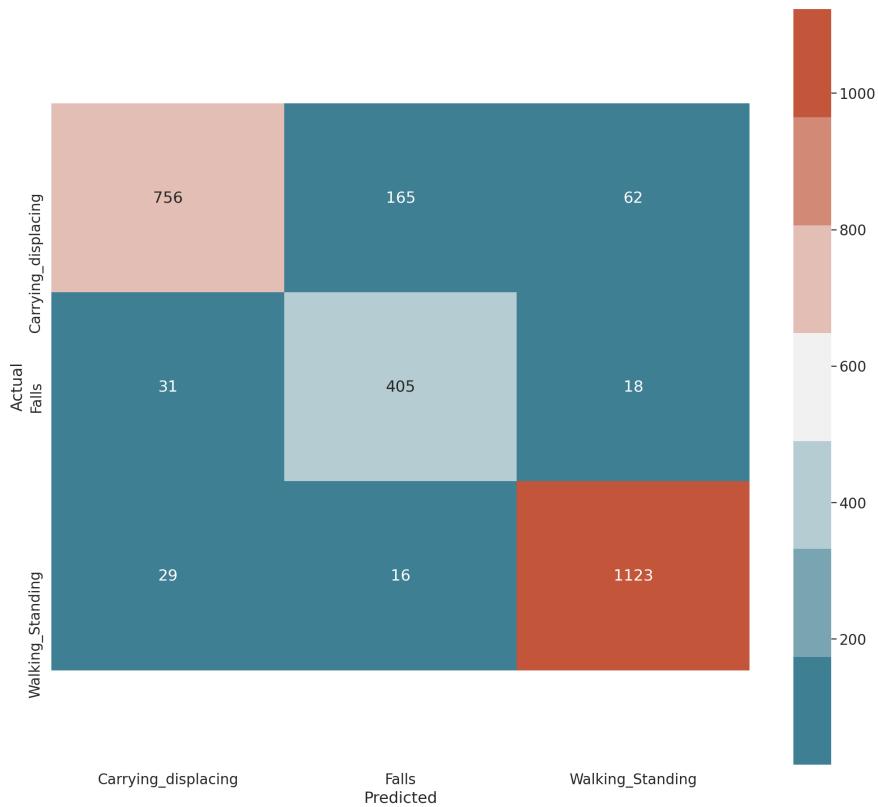


FIGURA 3.28: Matriz de confusión LSTM.

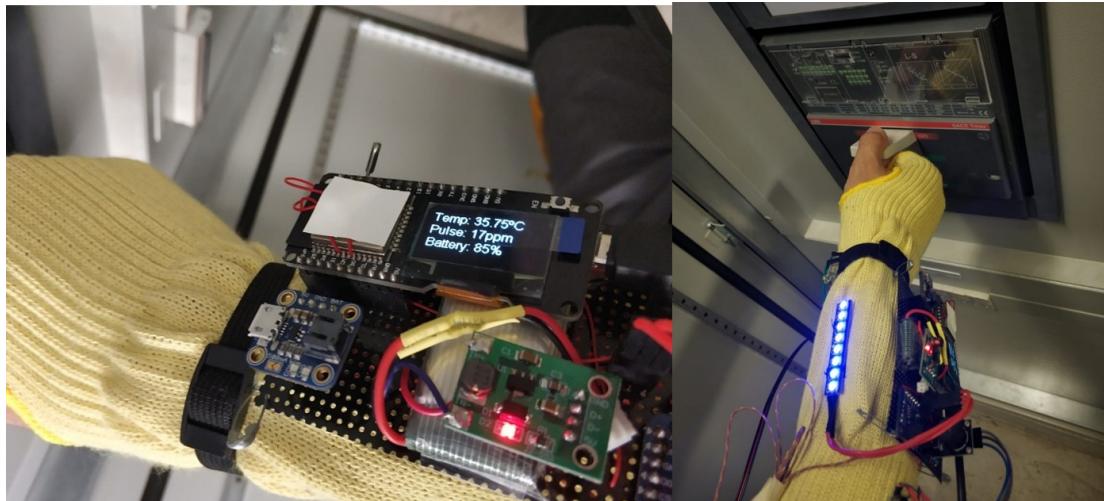


FIGURA 3.29: Imagen de los datos mostrados en la pantalla y de la alarma de pulso activa.

Por último, en la Figura 3.30 se muestra el panel de visualización del brazalete, como se puede ver, tenemos diferentes alertas de alarma. En base a su tipo se clasifica en un nivel de riesgo como se puede observar en los casos de alerta de pulso y temperatura corporal.

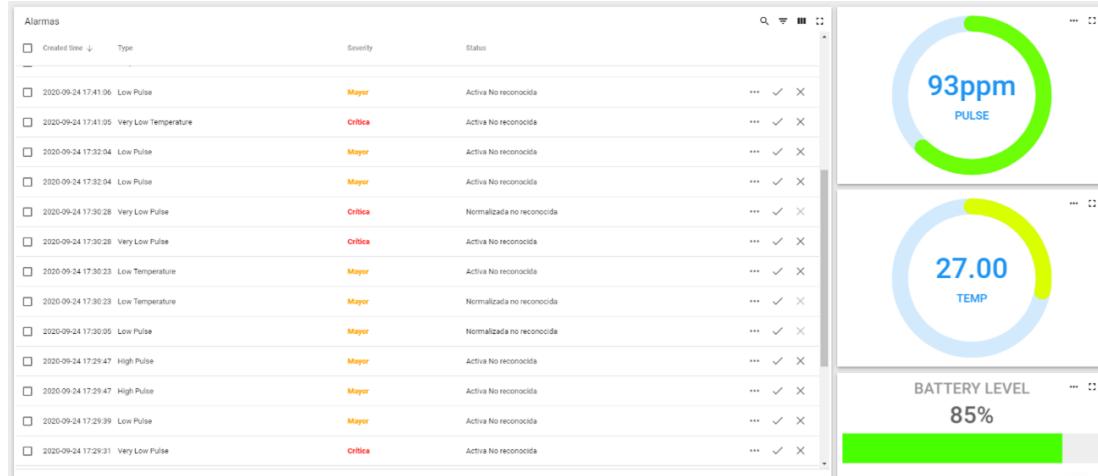


FIGURA 3.30: Panel de visualización del brazalete.

3.4.3. Cinturón inteligente

El estudio y desarrollo realizado para el cinturón inteligente (Rodríguez & Corchado, 2020) es muy similar a los dos anteriores. En este caso también si incluye un acelerómetro, combinado con un micrófono y botón de pánico. Al tener acelerómetros ubicados en diferentes partes del cuerpo, será un elemento positivo para la validación y comprobación de las señales por lo que este componente adquiere un especial valor en cada desarrollo. Cabe destacar que cada dispositivo además fue sometido a un análisis estadístico de Fisher para verificar la no superposición de clases. En el caso del cinturón, se obtuvieron las siguientes etiquetas en base a los problemas detectados con los sensores:

1. Batería baja
2. Diferencia del eje Z mayor que el valor bajo
3. Diferencia del eje Z mayor que el valor medio
4. Diferencia del eje Z mayor que el valor alto
5. Decibelios altos
6. Botón de pánico activado
7. Batería baja y diferencia en el eje Z mayor que el valor bajo
8. Batería baja y diferencia en el eje Z mayor que el valor medio
9. Batería baja y diferencia en el eje Z mayor que el valor alto

10. Batería baja y decibelios altos
11. Batería baja y botón de pánico activado
12. Diferencia en el eje Z mayor que el valor bajo y
13. decibelios altos
14. Diferencia en el eje Z mayor que el valor medio y decibelios altos
15. Diferencia en el eje Z mayor que el valor alto y los decibelios altos
16. Diferencia en el eje Z mayor que el valor bajo y botón de emergencia activado
17. Diferencia del eje Z mayor que el valor medio y botón de emergencia activado
18. Diferencia del eje Z mayor que el valor alto y botón de emergencia activado
19. Botón de pánico activado y decibelios altos
20. Diferencia del eje Z mayor que el valor bajo y decibelios altos y batería baja
21. Diferencia del eje Z mayor que el valor medio y decibelios altos y batería baja
22. Diferencia del eje Z mayor que el valor alto y decibelios altos y batería baja

En este caso, se implementó el algoritmo gaussiano Naïve Bayes para la clasificación, el cual tiene la característica de ser un modelo que permite un entrenamiento muy eficaz para un entorno de aprendizaje supervisado. En la Tabla 3.3 donde se observa la puntuación de cada clase en las medidas de evaluación. Por otro lado, cabe mencionar que para la estimación de los parámetros se utilizó el método de máxima verosimilitud.

TABLA 3.3: Evaluation measures for Naïve Bayes in the dataset

	precision	recall	f1-score	support
0	0.82	0.94	0.88	13667
1	0.71	0.95	0.81	2420
2	0.99	0.74	0.85	1235
3	0.98	0.87	0.92	7787
4	0.75	0.97	0.85	2114
accuracy	0.87	34488		
macro avg	0.88	0.86	0.85	34488
weighted avg	0.89	0.87	0.87	34488

El análisis de las curvas características operativas del receptor (Receiver Operating Characteristic Curve - ROC) se utiliza habitualmente para presentar resultados de problemas de decisión binarios en el aprendizaje automático. Las curvas ROC constituyen un método estadístico para determinar la precisión diagnóstica de estas pruebas. Definen el punto de corte en una escala continua donde se alcanza la mayor sensibilidad y especificidad, con los que evaluar la capacidad de discriminación de la prueba diagnóstica y comparar la capacidad de discriminación de dos o más pruebas diagnósticas que expresan sus resultados como escalas continuas (Cerda & Cifuentes, 2012; Davis & Goadrich, 2006). En la Figura 3.31 se muestra las curvas ROC para cada clase y el rendimiento del modelo Naïve Bayes.

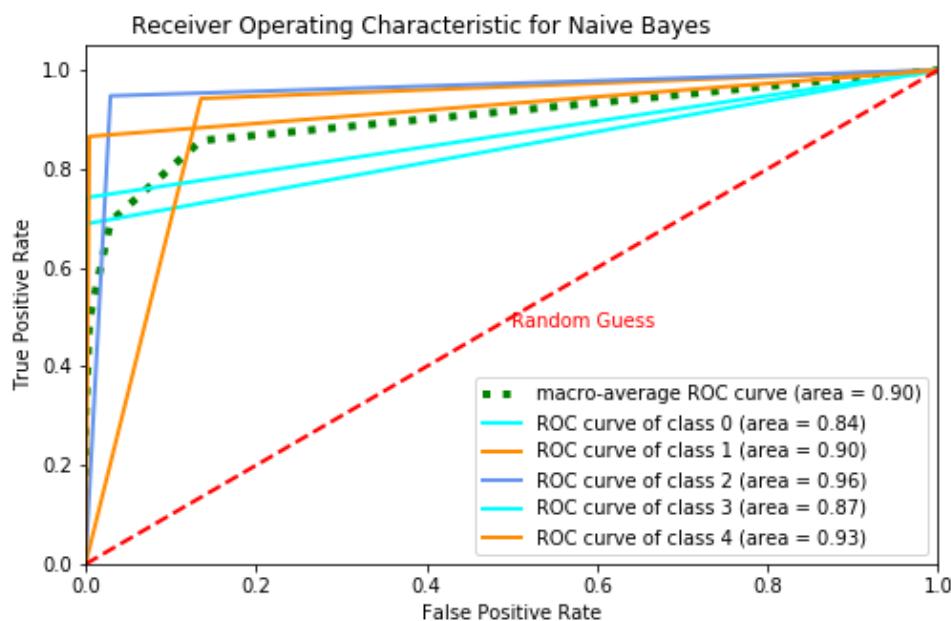


FIGURA 3.31: Curvas ROC para cada una de las clases representadas en la variable dependiente.

En las siguiente Figura 3.32 encontramos al operario colocando el cinturón:

En la validación, se hicieron una serie de comprobaciones del correcto funcionamiento de las alarmas, para lo cual se provocó ruido intenso y el operario simuló algunas caídas. Tal y como se puede comprobar en la Figura 3.33, donde se muestran algunas alertas detectadas así como la información mostrada en el panel de la interfaz del dashboard.

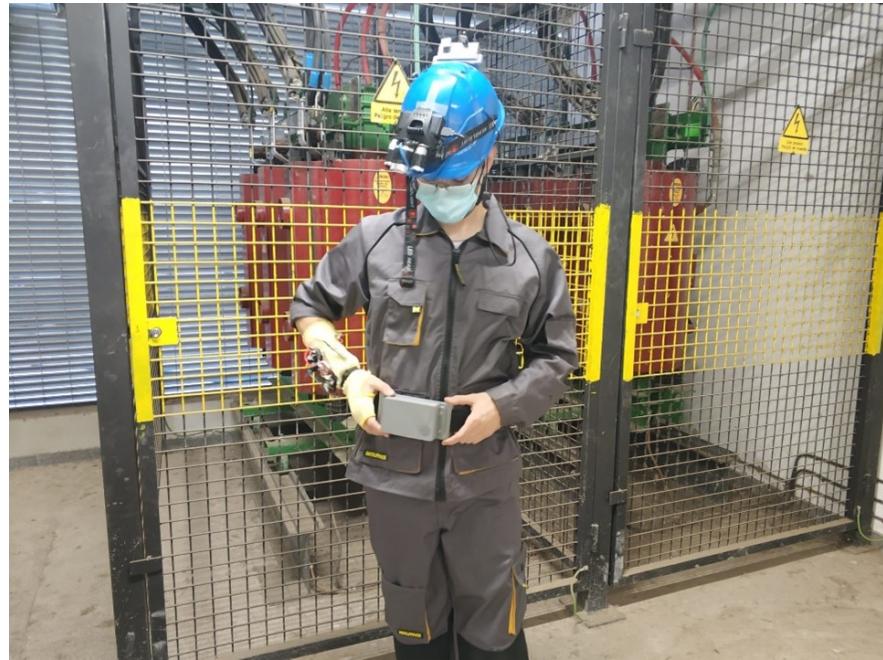


FIGURA 3.32: Operario configurando el cinturón en un centro de transformación.



FIGURA 3.33: Panel de visualización del cinturón.

3.4.4. Plataforma de soporte integral con procesamiento Edge e integración de los diferentes dispositivos

Finalmente, se presenta la plataforma con la integración de los diferentes modelos y etiquetas desarrollados para los diferentes casos de estudio, con el objetivo de integrar todo el proceso de toma de decisiones y que se pueda generalizar el voto (Márquez-Sánchez, Campero-Jurado, Herrera-Santos, et al., 2021). El aprendizaje automático (ML) es el estudio de los algoritmos informáticos que mejoran

automáticamente a través de la experiencia. Esto significa que es posible hacer predicciones o aproximaciones a partir de información con características similares. En el ML tenemos dos grandes categorías, el aprendizaje no supervisado y el supervisado. En este caso de estudio, trabajamos con el aprendizaje supervisado, que es una técnica para deducir una función a partir de los datos de entrenamiento. Los datos de entrenamiento consisten en pares de objetos (normalmente vectores): un componente del par son los datos de entrada y el otro son los resultados deseados. Para ello necesitamos crear un conjunto de datos de entrenamiento. Al hacer la validación en un conjunto de datos, elegimos una parte desconocida de la red multisensorial con el fin de evaluar su rendimiento del modelo. Habitualmente, en ML entrenamos los modelos con características que representen la naturaleza de los datos, y en el caso de querer diseñar una puntuación basada en la topología de un grafo, una opción es utilizar heurísticas. Donde las variables dependientes (salidas) de los conjuntos de datos indicarán si existe o no una relación entre cada conjunto de etiquetas de salida. Estas heurísticas tienen una aproximación muy cercana a las relaciones reales, lo que se puede comprobar mediante la evaluación de los datos reales frente a los datos obtenidos por cada heurística. Una vez que tenemos la heurística podemos utilizarla como elemento para entrenar nuestro modelo y luego utilizar esa información para tratar de predecir los vínculos entre la nueva red, cuando el conjunto de dispositivos se utiliza en tiempo real. El proceso general está descrito en (Silva & Zhao, 2016), donde nuestro objetivo es encontrar la relación entre las etiquetas de los 3 dispositivos y enviar una etiqueta número 41 que nos permita validar el correcto funcionamiento de toda la plataforma de seguridad. En resumen lo que se hace es lo siguiente (ejemplo dirigido a la predicción de enlaces, resumido en la Figura 3.34:

- Partiendo de un Gráfico elegimos un conjunto de heurísticas disponibles en el estado del arte para redes complejas, siendo las más comunes son: Coeficiente de Jaccard, Hub Promoted, Adamic Adar, etc.
- En referencia al Coeficiente de Jaccard se nos permite establecer un coeficiente para un nodo específico (definido por la similitud en base a la vecindad del nodo), este valor se convertirá en una característica para el vector de entrada que se utilizará para el modelado final.

- El proceso se repite asignando un valor por heurística a cada combinación de pares de nodos en la red, donde al final tendremos un vector de entrada para cada par de nodos con un objetivo que se identifica con 0 o 1 dependiendo de si existe o no un vínculo entre cada par de nodos.
- Por último, se aplica un modelo ML a los datos generados donde lo que se hace es ponderar la respuesta de los diferentes modelos de inteligencia artificial representados como una red compleja para reducir el ruido de clasificación en entornos industriales y laborales.

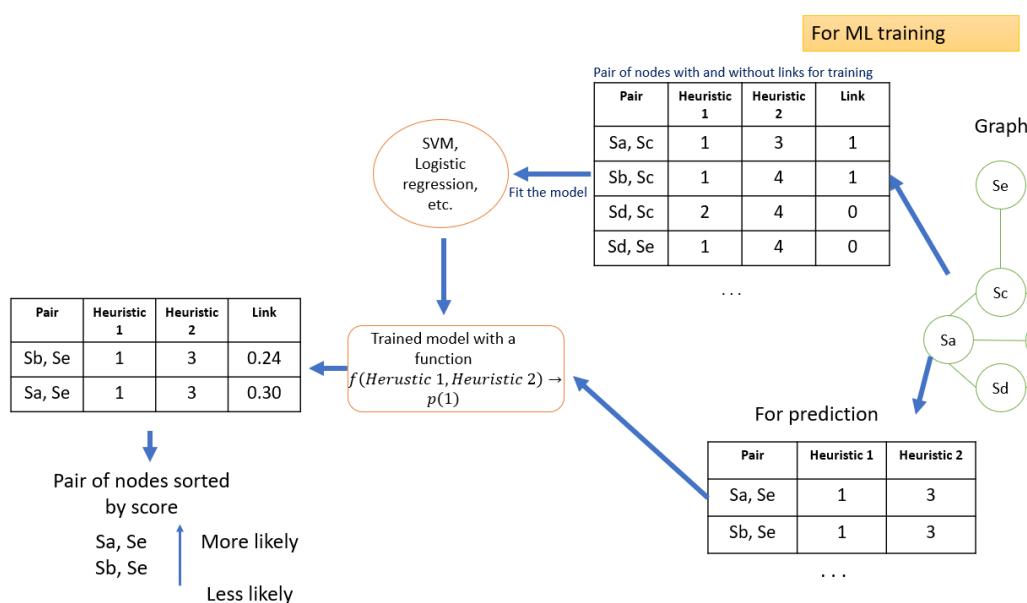


FIGURA 3.34: Explicación del proceso de inclusión del ML para la toma de decisiones conjuntas en toda una red. El flujo del diagrama es de derecha a izquierda.

Para integrar toda la información, por un lado, se ha realizado una comparación de los diferentes modelos utilizados con los dispositivos, entre los cuales tenemos la máquina de vectores de apoyo, el clasificador Naïve Bayes, una red neuronal estática y una red neuronal convolucional (ConvNet/CNN). Por otro lado, se ha recapitulado sobre las etiquetas asignadas en los diferentes desarrollos: en el caso del casco inteligente se contaba con 12 etiquetas posibles, el brazalete con un total de 7 etiquetas distribuidas en 2 modelos diferentes (GMM y LSTM), y finalmente el cinturón con total 21 etiquetas.

En este caso de estudio, se pretende ver cada una de las diferentes salidas como nodos de una red. Es por ello, que en este enfoque se busca no sólo analizar las 40 posibles etiquetas sino también estar preparados para posibles contingencias en las

que uno de los dispositivos esté inactivo o sea necesario reducir el ruido/riesgo de la predicción/clasificación. Para lo cual se propone el uso de heurísticas y aprendizaje automático con las que filtrar la información final de la red propuesta. En la Figura 3.35, se representa un diagrama con las etiquetas (salida final) de cada modelo, para crear un grafo que nos permita tener cada etiqueta representada como un nodo dado por un conjunto de datos independiente en cada modelo, donde el modelado de la información tenga resultados significativamente mejores que en los modelos tradicionales.

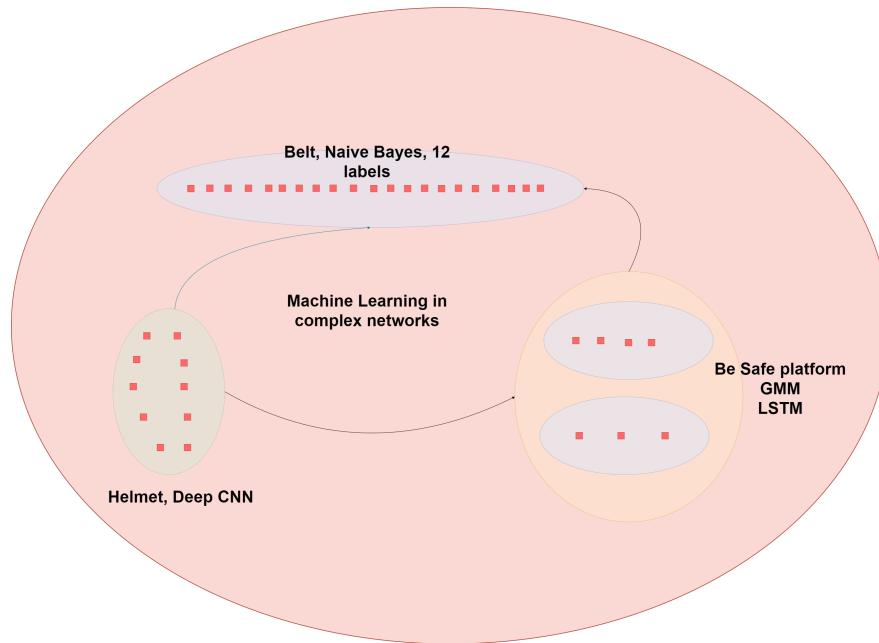


FIGURA 3.35: Interpretación final de los dispositivos mediante heurística y aprendizaje automático aplicado a redes complejas.

El gráfico creado con las diferentes etiquetas puede verse en la Figura 3.36. Esta imagen representa la relación que existe entre las etiquetas cuando se analizan los 3 dispositivos en paralelo y así dar respuestas conjuntas de todos los modelos. Como se ha mencionado, se busca reducir el riesgo de clasificación errónea encontrando la relación entre las etiquetas de salida de cada modelo, es decir, la entrada del análisis por heurística es la salida de los modelos de los dispositivos electrónicos. El resultado es la red generada con las diferentes salidas de los 4 modelos integrados, donde cada color representa la pertenencia a un determinado modelo. En concreto, los 3 nodos naranjas representan la salida del LSTM (3 clases), los 4 azules los 4 del GMM, los 12 verdes al CNN y el resto en rosa a los 21 de Naïve Bayes.

En base a lo anterior, realizamos una comparación entre una Gaussian Naïve Bayes, Random Forest, Support Vector Machine (SVM) y una Regresión Lineal donde el

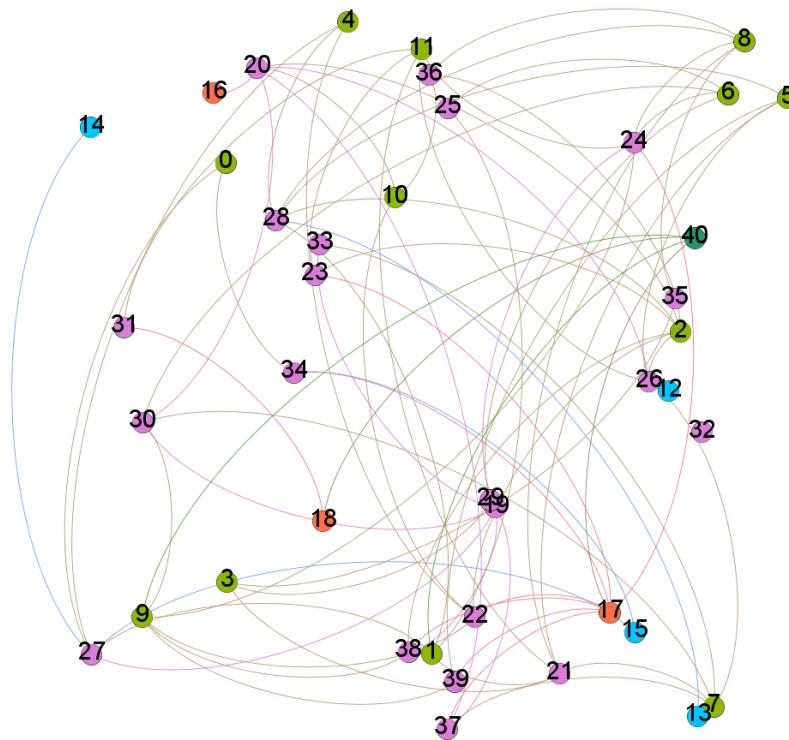


FIGURA 3.36: Imagen obtenida al trazar la red en el software Gephi.

resultado es bastante favorable según se puede observar en la Figura 3.37. Esto nos permite corroborar que existe una fuerte relación cuando alguna de las etiquetas advierte al usuario de un peligro en su entorno o se le alerta de sus signos vitales, así mismo, permite la integración de los 3 dispositivos que se han desarrollado.

Una vez integrados los 4 modelos de los 3 dispositivos diferentes, hay una analogía en el campo de la inteligencia artificial que es que un solo modelo no es tan bueno como varios modelos juntos buscando algo específico (analogía del elefante y los ciegos). Por ello, en base a los resultados podemos determinar que esta regla se cumple, y que varios de estos modelos tienen variables independientes en común, pero no están relacionados linealmente. Esto nos permite tomar una decisión basada en votos como un modelo AdaBoost, donde nuestro Boosting proviene de la independencia de cada conjunto de datos. La Red Compleja permite representar todas las salidas como nodos para facilitar el análisis y una vez hecho esto, podemos utilizar la heurística para determinar si una situación está ocurriendo realmente o no.

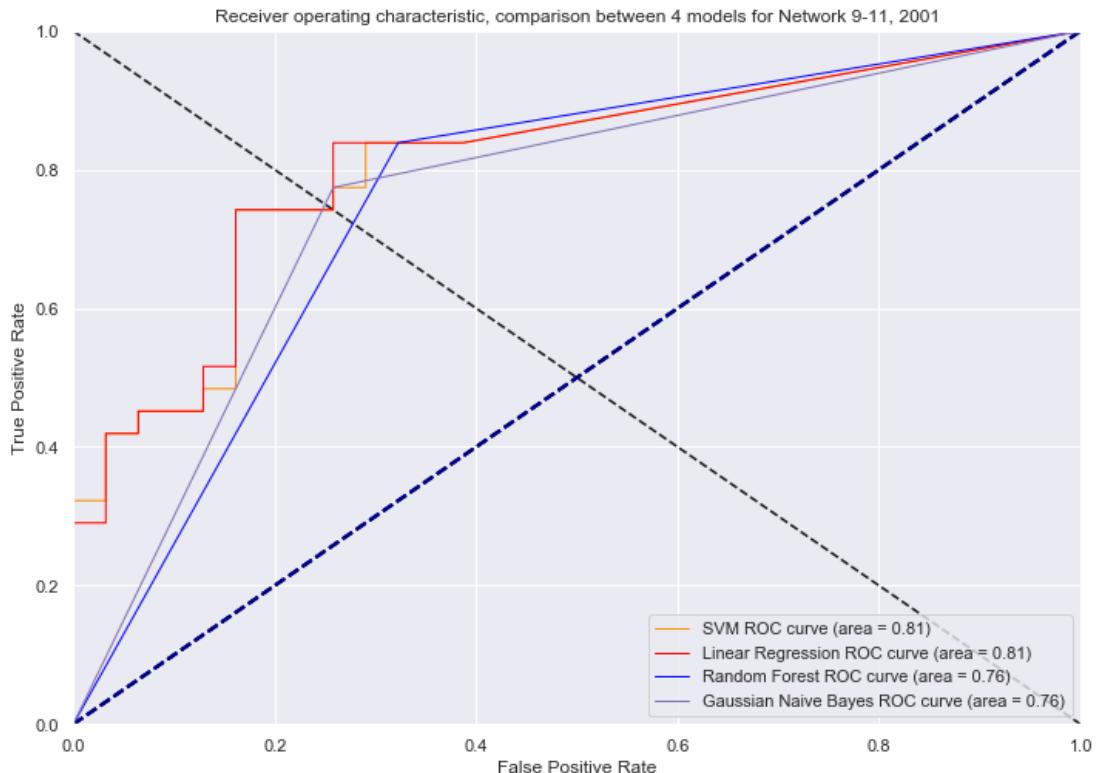


FIGURA 3.37: Curvas de características operativas del receptor (ROC) en el análisis de diferentes modelos para la integración de la multiplataforma completa.

3.5. Conclusiones

La Tesis Doctoral nace bajo el contexto y meta final, de anticipar riesgos y mejorar las condiciones de seguridad en el entorno laboral, gracias a la integración dentro de la arquitectura del sistema de diferentes tecnologías y el diseño modular de la misma. Esto se ha llevado a cabo realizando una fusión de datos provenientes de diferentes fuentes e integración y vinculación horizontal-vertical de las capas del sistema. El sistema tiene la capacidad de analizar el estado de los trabajadores y el entorno en donde desarrolle su actividad laboral, de forma que se maximice de detección de alertas y se anticipen los posibles riesgos, mediante una visualización en tiempo real de la situación en la que se encuentra el trabajador. La plataforma se fundamenta en tres capas que son: 1) capa hardware, monitorización del trabajador y su entorno, con la que adquirir el conocimiento de la realidad del contexto 2) capa Edge, donde un nodo central con altas capacidades, realice un preprocesamiento, detección temprana de riesgos y filtrado de datos 3) capa Cloud, donde aplicando IA se analiza y visualiza toda la información recogida, prediciendo situaciones anómalas para el trabajador.

En cuanto a la validación de la plataforma, por una parte, se ha comprobado su efectividad en un entorno de trabajo real y posteriormente, se ha utilizado un simulador que ha permitido recrear unas condiciones fidedignas para su correcta validación. Se han definido diferentes escenarios donde realizar las pruebas de validación del sistema y que han permitido obtener una muestra representativa del rendimiento y desempeño que tendrán cuando se encuentre en producción. Por otro lado, se han ejecutado pruebas de validación donde al menos se analizan los siguientes aspectos:

- Validación del funcionamiento del sistema en base a parámetros y métricas de eficiencia en la extracción y análisis de la información.
- Validación de las capacidades de cómputo del sistema en base a test de estrés.
- Análisis de la eficiencia y escalabilidad de la plataforma propuesta.

Por último, se ha evaluado las funcionalidades de la plataforma, identificando las posibles incidencias tanto en la inferencia de riesgos emergentes, como en procedimientos de trabajo, etc., recopilando información de los diferentes equipos para su análisis.

La novedad de la solución propuesta reside en su enfoque holístico, en donde se plantea una plataforma híbrida con capacidad de recepción de datos y generación de alarmas que combina el uso de dispositivos electrónicos wearables e IoT, Inteligencia Artificial y Edge Computing. Gracias a la combinación e integración de las tecnologías citadas se permite generar soluciones que mejoren la seguridad y productividad, se consigue disminuir las bajas laborales y a su vez tener un mayor control de la fábrica y operarios. Con ello se dota al sistema de mayores capacidades que las soluciones desarrolladas hasta ahora, creando un entorno mucho más favorable para la protección personal de los trabajadores. Además, el diseño de los dispositivos wearables permite que puedan ser utilizados en diferentes entornos de forma segura, consiguiendo así un diseño modular válido para los diferentes problemas que nos podemos encontrar en diferentes entornos o sectores de trabajo.

Capítulo 4

Publicaciones acreditativas de la investigación realizada



VNiVERSiDAD
D SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

Publicaciones acreditativas de la investigación realizada

Al tratarse de una Tesis Doctoral por compendio de artículos/publicaciones, el presente Capítulo recoge las publicaciones originales que el desarrollo de esta investigación ha generado. La Sección 4.1 incluye, en primer lugar, un artículo que presenta un casco inteligente que monitorea de forma continua el estado de los trabajadores y su entorno, evaluando los riesgos mediante la recogida y análisis de los datos utilizando Redes Neuronales Convolucionales - Deep Convolutional Neural Network (CNN). Comparando los resultados con una Red Neuronal Estática – Static Neural Network (NN), el clasificador Naïve Bayes - Naïve Bayes Classifier (NB) y la Máquina de Vectores de Apoyo – Support Vector Machine (SVM) (Campero-Jurado et al., 2020). La Sección 4.2, por su parte, recoge una publicación donde se realiza inicialmente una revisión del estado del arte de la electrónica aplicable a la contextualización del comportamiento de la actividad humana. Posteriormente se presenta un sistema híbrido compuesto de un brazalete inteligente multisensorial combinado con otros dispositivos, a cuyos datos se aplican los modelos de Mezclas Gaussianas - Gaussian Mixture Model (GMM) y Long short-term memory network (LSTM) para la Clasificación de la Actividad Humana (Márquez-Sánchez, Campero-Jurado, Robles-Camarillo, et al., 2021). La Sección 4.3, por su parte, presenta un artículo que describe una arquitectura compuesta por varios EPIs en combinación con modelos AI como redes neuronales convolucionales - Deep Convolutional Neural Network, Long short-term memory network (LSTM), modelos de Mezclas Gaussianas - Gaussian Mixture Model (GMM). Finalmente una máquina de vectores de soporte ponderó los votos de los modelos con un área bajo la curva (Márquez-Sánchez, Campero-Jurado, Herrera-Santos, et al., 2021).

4.1. Smart Helmet 5.0 for industrial internet of things using artificial intelligence

4.1.1. Información de la publicación

Título: Smart Helmet 5.0 for industrial internet of things using artificial intelligence.

Autores: Israel Campero Jurado^a, Sergio Márquez Sánchez^{b,d}, Juan Quintanar Gómez^c, Sara Rodríguez González^b, Juan Manuel Corchado Rodríguez^{b,d,e,f}.

Afiliaciones:

^a Laboratoire de l’Informatique du Parallelisme 46 allée d’Italie, 69007 Lyon, France

^bBISITE Research Group, University of Salamanca, Edificio I+D+i, C/ Espejo, Salamanca 37007, Spain.

^c Graduate school in information technology and communications Research department, Universidad Politécnica de Pachuca, 43830 Zempoala Hidalgo, Mexico.

^d Air Institute, IoT Digital Innovation Hub (Spain), 37188 Salamanca, Spain

^e Department of Electronics, Information and Communication, Faculty of Engineering, Osaka Institute of Technology, Osaka 535-8585, Japan

^f Faculty of Creative Technology & Heritage, Universiti Malaysia Kelantan, Locked Bag 01, 16300 Bachok, Malaysia **Publicado en:** *Sensors 2020, 20(21), 6241. Special Issue Developing “Smartness” in Emerging Environments and Applications with Focus on the Internet of Things (IoT)*

D.O.I.: <https://doi.org/10.3390/s20216241>

Fecha de publicación: 1 Noviembre 2020.

Factor de Impacto: 3.576 – Q1 (2020).

4.1.2. Introducción

La seguridad industrial es el conjunto de normas y actividades destinadas a prevenir y limitar los riesgos potenciales asociados a una industria, incluyendo tanto los riesgos transitorios como los permanentes (Gonzalez & et al., 2007; Zúñiga, 2003). Se han propuesto muchos protocolos de seguridad para mejorar la calidad de vida de los trabajadores utilizando diferentes técnicas (Chevalier et al., 2004; Vaughn Jr, Henning,

& Fox, 2002). Varios estudios han examinado cómo la disponibilidad de técnicas de inteligencia artificial (IA) podría afectar a la organización industrial tanto de los proveedores de servicios de IA como de las industrias que adoptan la tecnología de IA (Varian & et al., 2018). Sobre todo, se ha estudiado en profundidad el impacto de la IA en la industria 4.0 y sus posibles aplicaciones en otros campos (J. Lee, Davari, Singh, & Pandhare, 2018). La arquitectura del sistema descrita en el artículo integra la monitorización y detección de riesgos a través de un casco combinado con IA para crear un entorno que ofrezca mejores condiciones para el desarrollo industrial, maximizando de esta forma la toma de decisiones en situaciones simples o muy complejas como proponen Niu *et al.* (Barata & da Cunha, 2019; Niu et al., 2019), a través de la implantación de sistemas inteligentes de detección temprana de riesgos en el entorno laboral. Las principales contribuciones de la arquitectura propuesta residen en la generación de entornos más seguros en escenarios industriales, configurando un sistema, donde los datos procedentes de los sensores se adaptan para clasificarlos en una Red Neuronal Convolutacional, cuya precisión es del 92,05 % en validación cruzada comparada con otros 3 modelos de aprendizaje supervisado.

4.1.3. Objetivos

Este trabajo se enmarca dentro de las investigaciones relacionadas con el uso de IoT y la aplicación de Inteligencia Artificial, con el objetivo principal de generar un sistema que mejore la seguridad y salud en el trabajo (SST) y aumente el rendimiento de los empleados reduciendo la probabilidad de enfermedad, lesión, ausencia o muerte (Fernández-Muñiz, Montes-Péón, & Vázquez-Ordás, 2012) (OB1) y (OB2) según se ha definido en los objetivos Específicos en el Capítulo 1. En este sentido, la publicación incluye los siguientes objetivos concretos:

- Identificar las situaciones de riesgo comunes con los cuales definir las funcionalidades y requisitos que debe incorporar el casco.
- Investigación de los factores que permiten caracterizar el nivel de riesgo de una actividad en función del contexto, del trabajador y de los procedimientos que aplica.

- Diseño de nueva herramientas para la monitorización y protección de las personas en su entorno de trabajo, basado en un casco inteligente EPI.
- Identificación de los sistemas auxiliares de detección, aviso e identificación de riesgos, que puedan integrarse en el dispositivo diseñado.
- Incorporación de las metodologías de tratamiento de datos, uso de análisis de datos, algoritmos de prevención y despliegue de la plataforma de soporte.

4.1.4. Conclusiones

El trabajo engloba el desarrollo electrónico de un casco multisensorial (OB3). A través de un modelo condicional de reglas de entrada-salida, se busca detectar las diferentes situaciones a las que se vea sometido un trabajador(OB4). En base al análisis inicial, utilizando las técnicas de entrada-salida se presentaron falsos positivos y falsos negativos con un 60 % de precisión en el mejor de los casos. Por lo que finalmente tras varios estudios, se decidió implementar IA en el casco. Los falsos positivos y negativos, se debe a la combinación de diferentes circunstancias, en la mayor parte de los casos, a la correlación que existe sobre las características independientes. Es por ello, que dentro de esta publicación, se decidió innovar con técnicas de aprendizaje profundo que encuentran relaciones lineales y no lineales, con las cuales encontrar los patrones que determinan una acción particular. En la investigación se ha realizado la comparación entre diferentes modelos de IA (OB5), con la innovación de implementar una CNN, que en la literatura se ha utilizado principalmente para el análisis de imágenes o videos. Sin embargo, en la presente publicación se implementa en el análisis de características en tiempo real de un casco multisensorial diseñado para monitorizar las condiciones en un entorno de trabajo. Gracias al casco se pueden evitar diferentes lesiones, y en caso de que se produzca un accidente se disminuyen los daños causados al trabajador a través de una pronta atención o detección. Además, a través del uso de tecnologías como IoT podemos rápidamente realizar una sincronización de las alarmas que se envían a los supervisores con las que tomar medidas inmediatas.

4.1.5. Publicación original



Article

Smart Helmet 5.0 for Industrial Internet of Things Using Artificial Intelligence

Israel Campero-Jurado ^{1,†}, Sergio Márquez-Sánchez ^{2,*†}, Juan Quintanar-Gómez ³, Sara Rodríguez ² and Juan M. Corchado ^{2,4,5,6}

¹ Laboratoire de l'Informatique du Parallelisme 46 allée d'Italie, 69007 Lyon, France; israel.campero_jurado@ens-lyon.fr

² BISITE Research Group, University of Salamanca, Calle Espejo s/n. Edificio Multiusos I+D+i, 37007 Salamanca, Spain; srg@usal.es (S.R.); corchado@usal.es (J.M.C.)

³ Graduate School in Information Technology and Communications Research Department, Universidad Politécnica de Pachuca, Zempoala Hidalgo 43830, Mexico; juanquintanargomez@micorreo.upp.edu.mx

⁴ Air Institute, IoT Digital Innovation Hub (Spain), 37188 Salamanca, Spain

⁵ Department of Electronics, Information and Communication, Faculty of Engineering, Osaka Institute of Technology, Osaka 535-8585, Japan

⁶ Faculty of Creative Technology & Heritage, Universiti Malaysia Kelantan, Locked Bag 01, 16300 Bachok, Malaysia

* Correspondence: smarquez@usal.es; Tel.: +34-685-043-554

† These authors contributed equally to this work.

Received: 10 September 2020; Accepted: 27 October 2020; Published: 1 November 2020



Abstract: Information and communication technologies (ICTs) have contributed to advances in Occupational Health and Safety, improving the security of workers. The use of Personal Protective Equipment (PPE) based on ICTs reduces the risk of accidents in the workplace, thanks to the capacity of the equipment to make decisions on the basis of environmental factors. Paradigms such as the Industrial Internet of Things (IIoT) and Artificial Intelligence (AI) make it possible to generate PPE models feasibly and create devices with more advanced characteristics such as monitoring, sensing the environment and risk detection between others. The working environment is monitored continuously by these models and they notify the employees and their supervisors of any anomalies and threats. This paper presents a smart helmet prototype that monitors the conditions in the workers' environment and performs a near real-time evaluation of risks. The data collected by sensors is sent to an AI-driven platform for analysis. The training dataset consisted of 11,755 samples and 12 different scenarios. As part of this research, a comparative study of the state-of-the-art models of supervised learning is carried out. Moreover, the use of a Deep Convolutional Neural Network (ConvNet/CNN) is proposed for the detection of possible occupational risks. The data are processed to make them suitable for the CNN and the results are compared against a Static Neural Network (NN), Naive Bayes Classifier (NB) and Support Vector Machine (SVM), where the CNN had an accuracy of 92.05% in cross-validation.

Keywords: PPE; OHS; risk detection; naive Bayes; support vector machine; convolutional neural network; deep learning; microcontroller

1. Introduction

Industrial security is achieved when adequate measures and procedures are applied to obtain access to, handle or generate classified information during the execution of a classified contract or program. Industrial safety is the set of rules and activities aimed at preventing and limiting the potential risks associated with an industry, including both transient and permanent risks [1,2].

Many safety protocols have been proposed to improve the quality of life of workers using different techniques [3,4]. Several studies have examined how the availability of artificial intelligence (AI) techniques could affect the industrial organization of both AI service providers and industries adopting AI technology [5]. Above all, the impact of AI on industry 4.0 and its possible applications in other fields have been studied in depth [6].

In recent years, research has also been conducted on the applications of AI in the manufacturing industry [7–11]. The system architecture described in the article integrates technology together with communication systems and permits analyzing intelligent manufacturing. The provided information shows an overview of the possible applications of AI in all industrial areas.

AI allows to maximize decision making in simple or very complex situations. The AI boom that has taken place in the last decades has led to the development of countless AI applications in numerous areas. At present, increasingly better solutions are available to protect the lives of workers when they are exposed to high-risk conditions. That is why, in industry, AI is combined with security measures in order to create an environment that offers better conditions for industrial development.

The objective of the proposed device is to improve occupational health and safety (OHS); increasing employee performance by reducing the probability of illness, injury, absence or death [12]. Another objective is to contribute to the third wave, as proposed by Niu et al. [13,14], through the implementation of intelligent systems for early risk detection in the working environment.

Different studies have been conducted in creation of devices for occupational safety and health (OSH), which indicate the need to implement increasingly innovative solutions for workers in high-risk areas. For example, in 2014 [15] a study was conducted among 209 welders in India and it was found that all of them had more than 2 injuries and 44% (92) of them had more than 10 injuries. Furthermore, in 2020 [16] an analysis of workplace-related injuries in major industries such as agriculture, construction, manufacturing and health care has been carried out. The data for this analysis have been obtained from a Bureau of Labor Statistics and it was found that from 1992 to 2018, the number amounted to 4,471,340 injuries in the upper extremities, 3,296,547 in the lower extremities, and 5,889,940 in the trunk ($p < 0.05$). Therefore, the motivation behind this research is to propose an innovative helmet with different sensors such as temperature, humidity and atmospheric pressure, the force exerted between the helmet and the head of the user, the variations in axes, air quality and luminosity, through specialized IoT modules being able to have a faster reaction time to an accident in a work team. All the research papers that address the problem of occupational safety and health (OSH) are summarised in Table 1 with the purpose of comparing the improvements and advantages of similar research.

The information coming from the sensors is analyzed through a platform known as ThingsBoard. Independent alarms are configured using this information. Likewise, the data coming from the sensors are adapted to classify them in a Convolutional Neural Network, whose accuracy is of 92.05% in cross-validation compared to 3 other supervised learning models.

The remaining part of this work is organized as follows: Section 2 gives an overview of the related literature. Section 3 describes the system design. A multisensory helmet with communication in IIoT and AI-based information analysis is presented in Section 4. Finally, the last section describes future lines of research.

Table 1. OSH-related proposals.

Bibliography	Keywords	Novelty of the Proposal
Vaughn Jr, Rayford B. et al. (2002)		The state of security-engineering practices by three information security practitioners with different perspectives.
Choudhry, R. M., and Fang, D. (2008)	Security-engineering, Risk assessment	This work discusses empirical research aimed at why construction workers engage in unsafe behavior.
Niu, Yuhan, et al. (2019)		This research seeks to develop a smart construction object enabled OHS management system.
Champoux, D., and Brun, J. P. (2003)		This exploratory study based on telephone interviews with the owner-managers of small manufacturing enterprises gives an overview of the most characteristic OHS representations and practices in small firms.
Podgorski, Daniel, et al. (2017)	Occupational health and safety (OHS), Construction safety, Artificial Intelligence (AI)	A proposed framework based on a new paradigm of OSH risk management consisting of real-time risk assessment and risk level detection of every worker individually.
Barata, Joao et al. (2019)		Viable System Model (VSM) to design smart products that adhere to the organization strategy in disruptive transformations
Sun, Shengjing, et al. (2020)		A unified architecture to support the integration of different enabling technologies
Hasle, P., and Limborg, H. J. (2006)	Occupational health and safety, Accident Prevention	The scientific literature regarding preventive occupational health and safety activities in small enterprise.
Hasle, P., et al. (2011)	Occupational health and safety, Accident prevention	The investigation applied qualitative methods and theoretical approaches to CSR, small and medium-sized enterprises (SMEs), and occupational health and safety.
Abdelhamid, T. S., Everett, J. G. (2000)	Occupational safety, Construction safety,	Accident root causes tracing model (ARCTM) tailored to the needs of the construction industry.
Chi, S., Han, S. (2013)	Accidents prevention	This study incorporates the systems theory into Heinrich's domino theory to explore the interrelationships of risks and break the chain of accident causation.
Cambraia, F. B., et al. (2010)	Incident reporting systems, Safety management	Guidelines for identifying, analyzing and disseminating information on near misses in construction sites.
Chevalier, Yannick, et al. (2004)	Network security, Cryptographic protocols	High level protocol specification language for the modelling of security-sensitive cryptographic protocols.

2. Related Works

Protective equipment is of obligatory use in cases where the safety of the worker is at risk. However, detecting hazardous situations in a timely manner is not always possible, leading to the occurrence of accidents. Such events call the worker's health and safety into question; the confidence of the worker in the company for which they work decreases [17–19]. For effective prevention of injuries or fatal accidents in the working environment, the integration of electronic components is crucial given their ability for early risk detection. The research of Henley, E.J. and Kumamoto, H [20] proposed a quantitative approach for the optimal design of safety systems which focused on information links (human and computer), sensors, and control systems. In 2003, Condition Monitoring (CM) was addressed in the research of Y. Han and Y. H. Song [21] including a review of popular CM methods, as well as the research status of CM transformer, generator, and induction motor, respectively. In December 2001, the factor structure of a safety climate within a road construction organization was determined by A.I Glendon and D.K Litherland [22]; a modified version of the safety climate questionnaire (SCQ). They also investigated the relationship between safety climate and safety performance. In March 2011, Intelligent Internet of Things for Equipment Maintenance (IITEM) was presented by Xu Xiaoli et al. [23]. The static and dynamic information on electrical and mechanical equipment is collected by IITEM from all kinds of sensors, and the different types of information are standardized, facilitating Internet of Things information transmission [24,25]. The investigations that address motion monitoring and sensor networks have been compiled in Table 2.

Table 2. Proposals related to sensor networks.

Bibliography	Keywords	Novelty of the Proposal
Zhou, Yinghui, et al. (2012)		Wearable device based on a tri-axis accelerometer, which can detect acceleration change of human body based on the position of the device being set.
Zhu, C., and Sheng, W. (2009)	Internet of Things, Wearable Computing, Robot sensing systems, Acceleration Feature analysis	A human daily activity recognition method by fusing the data from two wearable inertial sensors attached on one foot and the waist of the subject.
Lindeman, Robert W., et al. (2006)	Human-computer interaction	A development history of a wearable, scalable vibrotactile stimulus delivery system.
Kim, Sung Hun, et al. (2018)		Experiments were performed in which the sensing data were classified whether the safety helmet was being worn properly, not worn, or worn improperly during construction workers' activities.
Nithya, T., et al. (2018)	Head motion recognition, Hazardous gas, Temperature measurement, Sensor System, IMU,	Smart helmet able to detect hazardous events in the mining industry and design a mine safety system using wireless sensor networks.
Li, Ping, et al. (2014)	Electroencephalography (EEG)	Smart Safety Helmet (SSH) in order to track the head gestures and the brain activity of the worker to recognize anomalous behavior.
Fang, Y., et al. (2016)	Crane safety, Human errorReal-time, Crane motion capturing	A prototype system was developed based on the framework and deployed on a mobile crane.
Cao, Teng, et al. (2014)	Steady-state visual evoked potential (SSCEP), Brain-computer interfaces (BCIs)	Propose a method for the real-time evaluation of fatigue in SSVEP-based BCIs.

Moreover, an Accident Root Causes Tracing Model (ARCTM), tailored to the needs of the construction industry, has been presented by Tariq S. Abdelhamid and John G. Everett [26]. In January 2010, guidelines for identifying, analyzing and disseminating information on near misses at construction sites were defined by Fabricio BorgesCambraia et al. [27]. In September 2013, three case studies were presented by Tao Cheng and Jochen Teizer [28] which employed methods for recording data and visualizing information on construction activities at a (1) simulated virtual construction site, (2) outdoor construction setting, and (3) worker training environment. Furthermore, systems theory has been incorporated in Heinrich's domino theory by Seokho Chia and Sangwon Han [29] to explore the interrelationships between risks and to break the chain of accident causation. In April 2008, the reasons for which construction workers engage in unsafe behavior were discussed in the empirical research of Rafiq M. Choudhry and Dongping Fang [30]. Interviews were conducted in Hong Kong with workers who had been accident victims. In addition, Daniel Fitton et al. [31] applied augmented technology with sensing and communication technologies which can measure use in order to enable new pay-per-use payment models for equipment hire. The areas in which it is necessary to create a safer working environment are listed in Table 3. This can be achieved through the use of sensors for the monitoring environmental parameters and capturing motion.

In December 2008, the underlying biomechanical elements required to understand and study human movement were identified by A. Godfrey et al. [32]. A method for investigating the kinematics and dynamics of locomotion without any laboratory-related limitations has been developed by Yasuaki Ohtaki et al. [33]. In April 2012, the usage of the Unscented Kalman Filter (UKF) as the integration algorithm for the inertial measurements was proposed by Francisco Zampella et al. [34]. Furthermore, in 2012, a micro wearable device based on a tri-axis accelerometer was introduced by Yinghui Zhou et al. [35]. It can detect change in the acceleration of the human body on the basis of the position of the device. In 2009, a method for the recognition of daily human activities was developed by Chun Zhu and Weihua Sheng [36]. This method involved fusing the data from two wearable inertial sensors attached to the foot and the waist of the subject. In October 2012, Martin J.-D. Otis and Bob-Antoine J. Menelas [37] reported an ongoing project whose objective was to create intelligent clothes for fall prevention in the work environment. In 2007, a signal transform method, called Common Spatial

Pattern, was introduced by Hong Yu et al. [38] for Electroencephalographic (EEG) data processing. In March 2006, the development history of a wearable, called the scalable vibrotactile stimulus delivery system, was presented by Robert W. Lindeman et al. [39]. In 2014, an objective and real-time approach based on EEG spectral analysis for the evaluation of fatigue in SSVEP-based BCIs was proposed by Teng Cao et al. [40].

Table 3. Proposals related to safety environment and motion recognition.

Bibliography	Keywords	Novelty of the Proposal
Fernández-Muñiz, B., et al. (2012)	Safety climate, Employee perceptions, Safety performance	The current work aims to analyse the safety climate in diverse sectors, identify its dimensions, and propose to test a structural equation model that will help determine the antecedents and consequences of employees' safety behaviour.
Glendon, A. I., Litherland, D. K. (2001)		A behavioral observation measure of safety performance and a road construction organization using a modified version of the safety climate questionnaire (SCQ).
Han, Y., and Song, Y. H. (2003)		After introducing the concepts and functions of CM, this paper describes the popular monitoring methods and research status of CM on transformer, generator, and induction motor, respectively.
Godfrey, A. C. R. M. D. O. G., et al. (2008)	IMU, Magnetometers, Gyroscopes, Accelerometer, Human motion	The underlying biomechanical elements necessary to understand and study human movement.
Ohtaki, Y., et al. (2001)		A new method is proposed to investigate kinematics and dynamics of locomotion without any limitation of laboratory conditions.
Zampella, Francisco, et al. (2012)		The usage of the Unscented Kalman Filter (UKF) as the integration algorithm for the inertial measurements.
Cheng, T., and Teizer, J. (2013)		A novel framework is presented that explains the method of streaming data from real-time positioning sensors to a real-time data visualization platform.
Bleser, Gabriele, et al. (2015)	Body sensor network (BSN), Vision Algorithms, Augmented reality (AR) Virtual Reality (VR), Location tracking,	Assistance system based in the last advances in hardware, software and system level.
Fitton, Daniel, et al. (2008)		Investigation into how physical objects augmented with sensing and communication technologies can measure use in order to enable new pay-per-use payment models for equipment hire.
Yu, H., et al. (2007)	Measuring vigilance, Sensor network, Intelligent sensors	Signal transform method, Common Spatial Pattern, to process the EEG data.
Qiang, Cheng, et al. (2009)		A cost effective ZigBee-based wireless mine supervising system

Thanks to the implementation of communication technologies, it is possible to notify both the managing staff and the workers about the hazards encountered in a particular working area. A helmet that implements Zigbee transmission technologies for the analysis of variables such as humidity, temperature and methane in mines has been developed by Qiang et al. (2009) [41]. This helmet helps decrease the risk of suffering an accident during the coal extraction process. An intelligent helmet for the detection of anomalies in mining environments was also proposed by Nithya et al. (2018) [42]. This research points to the possibility of integrating components in the PPE that would alert the worker of the presence of danger. Moreover, the vital signs of the worker are monitored by their helmet, making it possible to monitor their state of health. An emergency button on the helmet is used for the transmission of alerts via Zigbee technologies to the personnel nearest to the working environment. Accelerometers have been integrated in safety helmets by Kim et al. (2018) [43], with the purpose of detecting if the safety helmet is being worn properly, improperly or not worn at all while the worker performs their tasks. In December 2016, a framework for real-time pro-active safety assistance was developed by Yihai Fang et al. [44] for mobile crane lifting operations.

Ensuring the physical well-being of workers is the responsibility of employers. Better protection is offered to today's workers thanks to PPE helmets by protecting the worker from blows to the head. However, monitoring other aspects for the worker's security is important in some cases. Li et al. (2014) [45] developed a helmet which, by means of sensors, measures the impact of blows to the worker's head. Sensors for brain activity detection are also implemented in the helmet. In terms of movement, identifying the position of the worker is essential in order to detect falls that result in physical injury or fatal accidents.

In 2019, Machine Learning (ML) algorithms for the prediction and classification of motorcycle crash severity were employed in a research by Wahab, L., and Jiang, H. [46]. Machine-learning-based techniques are non-parametric models without any presumption of the relationships between endogenous and exogenous variables. Another objective of this paper was to evaluate and compare different approaches to modeling motorcycle crash severity as well as investigating the risk factors involved and the effects of motorcycle crashes. In 2015, a scalable concept and an integrated system demonstrator was designed by Bleser, G. et al. [47]. The basic idea is to learn workflows from observing multiple expert operators and then transferring the learned workflow models to demonstrate the severity of motorcycle crashes. In 2019, an intelligent video surveillance system which detected motorcycles automatically was developed by Yogameena, B., Menaka, K., and Perumaal, S. S. [48]. Its purpose was to identify whether motorcyclists were wearing safety helmets or not. If the motorcyclists were found without the helmet, their License Plate (LP) number was recognised and legal action was taken against them by the traffic police and the legal authority, such as assigning penalty points on the motorcyclists' vehicle license and Aadhar Number (Applicable to Indian Scenario). In 2017, a comparison of four statistical and ML methods was presented by Iranitalab, A., and Khattak [49], including Multinomial Logit (MNL), Nearest Neighbor Classification (NNC), Support Vector Machines (SVM) and Random Forests (RF), in relation to their ability to predict traffic crash severity. A crash costs-based approach was developed to compare crash severity prediction methods, and to investigate the effects of data clustering methods—K-means Clustering (KC) and Latent Class Clustering (LCC)—on the performance of crash severity prediction models. These novel proposals are compiled in Table 4. They employ artificial intelligence and machine learning, and suppose a significant improvement in different scenarios.

In 2005, the results obtained with the random forest classifier were presented in the research of M. Pal [50] and its performance was compared with that of the support vector machines (SVMs) in terms of classification accuracy, training time and user defined parameters. In January 2012, the performance of the RF classifier for land cover classification of a complex area was explored by V. F. Rodriguez-Galiano et al. [51]; the evaluation was based on several criteria: mapping accuracy, sensitivity to data set size and noise. Furthermore, in February 2014, a random forest classifier (RF) approach was proposed by Ahmad Taher Aza et al. [52] for the diagnosis of lymph diseases. In April 2016, the use of the RF classifier in remote sensing was reviewed by Mariana Belgua and Lucian Drăguț [53]. Besides, in 2015, machine learning approaches including k-nearest neighbor (k-NN), a rules-based classifier (JRip), and random forest, were investigated by Esrafil Jedari et al. [54] to estimate the indoor location of a user or an object using RSSI based fingerprinting method. Finally, in July 2011, a method utilizing Healthcare Cost and Utilization Project (HCUP) dataset was presented by Mohammed Khalilia et al. [55] for predicting disease risk in individuals on the basis of their medical history.

With regard to CNN in 2020, an automated system for the identification of motorcyclists without helmets from real-time traffic surveillance videos was presented by Shine L. and Jiji, C. V. [56]. A two-stage sorter was used to detect motorcycles in surveillance videos. The detected motorcycles were fed in a helmet identification stage based on a CNN. Moreover, in July 2019, the same approach to detecting the absence of helmets on motorcyclists with or without helmets was presented by Yogameena B. et al. [48]; it was different in that it combined a CNN with a Gaussian Mixture Model (GMM) [57]. Furthermore, in 2020, a system that uses image processing and CNN networks was developed by Raj K. C. et al. [58] for the identification of the motorcyclists who violate helmet laws.

The system includes motorcycle detection, helmet vs. helmetless classification and motorcycle license plate recognition. As can be observed, CNNs have been used mainly for real-time image processing. However, the use of CNN for linear data evaluation is proposed in this paper. Here, CNN is integrated (input-output) in a rules model for the classification of different problems in working environments. The presented papers are examples and inspired the given research as a support for this paper. A diagram of the most represented technologies in the state of the art is given in Figure 1. These technologies are the main basis of the proposal.

Table 4. Proposals related to Smart manufacturing and Machine Learning.

Bibliography	Keywords	Novelty of the Proposal
Lee, Jay, et al. (2018)		State of AI technologies and the eco-system required to harness the power of AI in industrial applications.
Henley, E. J., and Kumamoto, H. (1985)		Provides a quantitative treatment of the optimal design of safety systems focusing on information links (human and computer), sensors, and control systems.
Li, Bo-hu, et al. (2017)	Artificial Intelligent Smart manufacturing, Fault diagnosis	Based on research into the applications of artificial intelligence (AI) technology in the manufacturing industry in recent years.
Xiaoli, X. et al. (2011)		A presentation of Intelligent internet of things for equipment maintenance (IITEM) which we can make intelligent processing of device information.
Varian, Hal. (2018)		Summary of some of the forces at work and to describe some possible areas for future research.
Wahab, L., and Jiang, H. (2019)		Traffic crash analysis using machine learning techniques.
Azar, A. T., et al. (2014)		A random forest classifier (RFC) approach is proposed to diagnose lymph diseases.
Belgiu, M., and Drăguț, L. (2016)		This review has revealed that RF classifier can successfully handle high data dimensionality and multicollinearity, being both fast and insensitive to overfitting.
Khalilia, M., et al.		Method for predicting disease risk of individuals using random forest.
Jedari, E., et al. (2015)	Machine Learning (ML), Decision Tree Classifier (DTC), Random Forest (RF), Multinomial logic model (MNL), Support vector machine (SVMs), Receiver operating characteristic (ROS)	Machine learning approaches including k-nearest neighbor (k-NN), a rules-based classifier (JRip), and random forest have been investigated to estimate the indoor location of a user or an object using RSSI based fingerprinting method.
Iranitalab, A., and Khattak, A. (2017)		This paper had three main objectives: comparison of the performance of four statistical and machine learning methods including Multinomial Logit (MNL), Nearest Neighbor Classification (NNC), Support Vector Machines (SVM) and Random Forests (RF), in predicting traffic crash severity.
Pal, M. (2005)		To present the results obtained with the random forest classifier and to compare its performance with the support vector machines (SVMs) in terms of classification accuracy, training time and user defined parameters.
Rodriguez-Galiano, V. F., et al. (2012)		The performance of the RF classifier for land cover classification of a complex area is explored.
Yogameena, B., et al. (2019)	Complex software system, Mixture models,	Intelligent video surveillance system for automatically detecting the motorcyclists with and without safety helmets.
Cockburn, D. (1996)	Convolutional neural networks	The benefit of taking a holistic perspective to developing complex software systems.

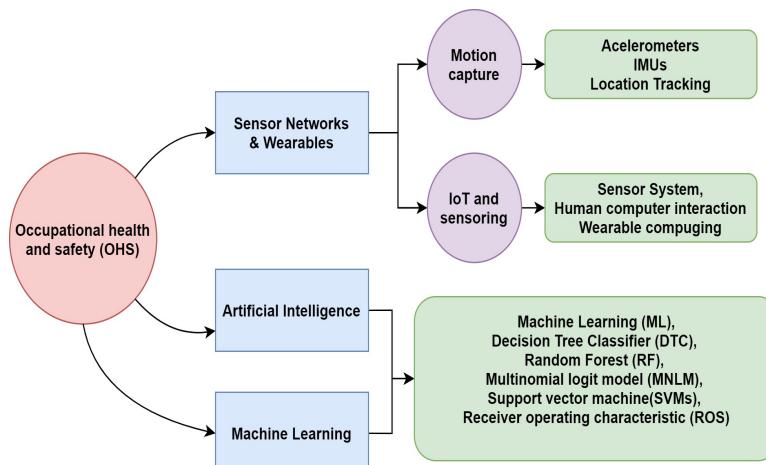


Figure 1. A block diagram of the devices.

3. Smart Helmet 5.0 Platform

There are different methodologies for carrying out research on electronics and system design. Thus, in this section, a description of the hardware and software used for the development of the fifth version of the smart helmet will be presented, and the procedure followed for its subsequent validation through the AI model will be detailed. The four previous helmets included less sensorisation and connectivity, which is why we developed a new version with all the improvements.

3.1. Hardware Platform

The structure followed in the development of the proposed helmet are the steps involved in the prototype development methodology, identifying the parameters to be monitored in the environment. A Job Safety Analysis (JSA) was performed, identifying the risk factors that lead to injuries and accidents in the worker [59]. The deficiencies that have been observed are presented in Table 5 for work places such us mines, construction places and electrical work areas. They are related to aspects such as lighting, detection of blows to the worker's helmet (PPE detection), dangerous temperature levels for human activityand poor air quality in the environment. Other parameters that could be interesting such as, noise, rate pulse and body temperature are implemented in other devices for better ergonomics.

Table 5. Identification of common risk situations in the worker's environment.

Risk Factors	Associated Hazards
Lack of Adequate Lighting	- The inability of the worker to see their environment clearly leads to accidental hits, slips, trips and falls. - The worker is unaware of the events occurring in their environment.
Temperature	- Extreme temperature changes leading to a heat stroke
Air Quality	- Harmful air in the environment
Operator Movement	-Slips, trips and falls -Blows to the worker's head

Given the above, a series of specialized sensors are proposed to counteract the difficulties that usually occur in a high-risk work environment [1], see Table 6. As seen in the literature review, agriculture and industrial activities involve high risk, among others.

Table 6. Identification of electronic components for the prevention of risks in the worker's environment.

Risk Factors	Solution
Lack of Adequate Lighting	- Implementation of a brightness sensor in the helmet - Inclusion of torches as one of the tools of worker
Temperature	- Implementation of temperature sensors in the devices of the worker or environment
Air Quality	-Moisture and gas sensors.
Operator Movement	- The use of wearable devices with accelerometers capable of detecting falls. - Integration of sensitive force resistors in the helmet of the operator.

In terms of the transmission of information from sensors, the use of Wi-Fi technologies has been selected due to their ability to transmit the information in Local Area Networks (LAN) to a web server responsible for collecting, processing and transmitting anomaly warnings to the worker or administrative personnel. The following describes the system design and the interaction of the components.

The elements used in the smart helmet and the risks it seeks to prevent or detect are detailed below. The operation of the Smart PPE and the distribution of the circuits will also be discussed. In addition, the architecture and technologies are explained, as well as the operating rules of the different sensors and actuators that make up the system. Finally, their communication system is considered, as well as the technology used for both the management of the data and for its visualization and treatment once obtained.

The aim of this Smart PPE is to protect the operator from possible impacts, while monitoring variables in their environment such as the amount of light, humidity, temperature, atmospheric pressure, presence of gases and air quality. At the same time, the Smart PPE is to be bright enough to be seen by other workers, and the light source will provide extra vision to the operator. All these alerts will be transmitted to the operator by means of sound beeps. The sensors described below were selected as part of the set of electronic devices to be implemented:

- Temperature, gas and pressure sensor;
- Brightness sensor;
- Shock sensor;
- Accelerometer.

In the process of the visualization of environmental data, a LED strip is deployed on the helmet as a means of notifying the worker of anomalies through color codes presented in the environment. The block diagram shown in Figure 2 is a representation of the electronic system integrated in the helmet.

The specifications of the sensors and the microcontroller used to monitor the environment are defined as follows:

The component used to supervise the parameters of gas, pressure, temperature and humidity is the low power environmental sensor DFRobot BME680. It is a MEMS (Micro-Electromechanical System) multifunctional 4 in 1 environmental sensor that integrates a VOC (Volatile Organic Compounds) sensor, temperature sensor, humidity sensor and barometer. The environmental pressure is subject to many short-term changes caused by external disturbances. To suppress disturbances in the output data

without causing additional interface traffic and processor work load, the BME680 features an internal IIR filter. The output of the subsequent measurement step is filtered using the following Equation (1):

$$x_{filt}[n] = \frac{x_{filt}[n-1] * (c - 1) + x_{ADC}}{c} \quad (1)$$

where $x_{filt}[n-1]$ is the data coming from the current filter memory, and x_{ADC} the data coming from current ADC acquisition and where $x_{filt}[n]$ denotes the new value of filter memory and the value that will be sent to the output registers.

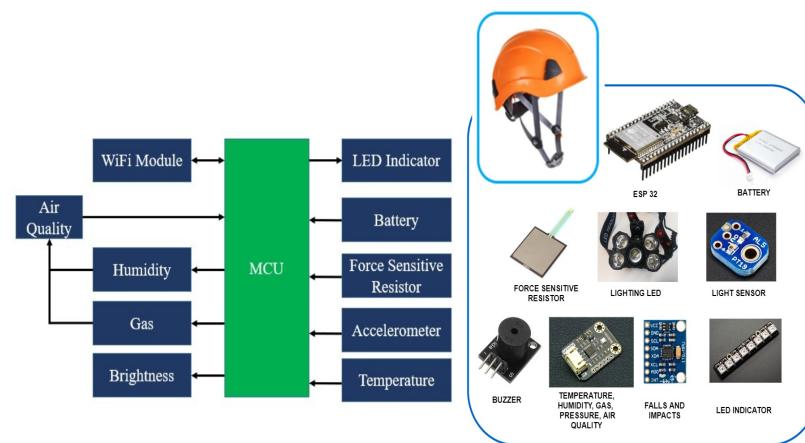


Figure 2. A block diagram of the devices.

The sensor implemented for the monitoring of the level of brightness is the ALS-PT19 ambient light sensor. Due to the high rejection ratio of infrared radiation, the spectral response of the ambient light sensor resembles that of the human eyes.

The sensor implemented for shock detection is a sensitive force resistor, the sensor emits shock alerts if the readings obtained in the environment exceed a threshold value.

The sensor responsible for the detection of falls suffered by the worker is the MPU6050 module, it is an electronic component that has six axes (three corresponding to the gyroscope system and three to the accelerometer) making it possible to obtain the values of positioning in the X, Y and Z axes.

The light source integrated in the helmet is a NeoPixel Adafruit LED strip, the component integrates a multicolor LED in each section of the strip. The algorithm implemented in the microcontroller is configured in such a way that it is possible to control the color of the LED strip.

The microcontroller used for processing, transmitting and displaying the information transmitted to the web platform is the dual-core ESP-WROOM-32 module of the DFRobot FireBeetle series, which supports communication through Wi-Fi and Bluetooth. The main controller supports two power methods: USB and 3.7 V external lithium battery.

The components are integrated in the microcontroller, which obtains and processes the information coming from the sensors. This information is then transmitted to the implemented web server by means of the Wi-Fi module. The designed electronic system is located in the backside of the helmet, as shown in Figure 3. It also integrates a lamp which is activated automatically if the brightness value of the sensor is below the threshold value established in the programming of the microcontroller. The information transmitted by the helmet can be viewed on a web platform.

This section describes the developed software and the interaction that takes place between the different components.

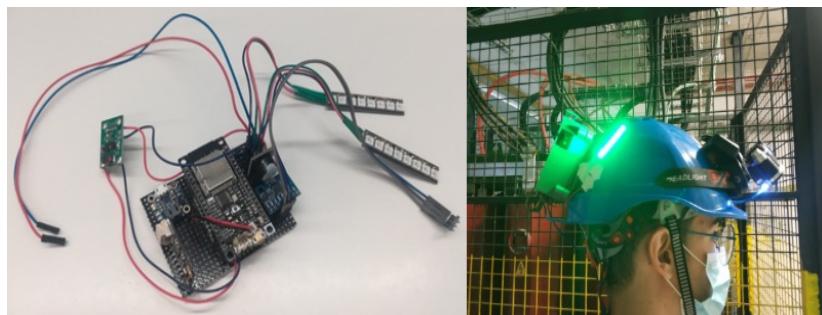


Figure 3. The electronic system of the helmet.

3.2. Intelligence Module

Firstly, the communication between the active sensors is enabled by Thingsboard. ThingsBoard is an open source IoT platform for data collection, processing, visualization and IoT device management. It is free for both personal and commercial use and can be implemented anywhere.

It enables device connectivity through industry-standard IoT protocols (MQTT, CoAP and HTTP) and supports both cloud and on-premise deployments. ThingsBoard combines scalability, fault tolerance and performance, ensuring that the users' data are never lost.

ESP32 is a series of low-power, low-consumption system-on-a-chip microcontrollers with integrated Wi-Fi and dual-mode Bluetooth, as mentioned in the previous section. The device is responsible for transmitting the information to the ThingsBoard platform and its subsequent processing by the intelligent model see Figure 4, to interact with the helmet.



Figure 4. Setting up the ThingsBoard platform to operate according to the information received from ESP32, IoT module added to ThingsBoard and Multi-sensorial configuration.

Simple steps are required to link the devices to the platform:

- The automatically generated access token is copied from the Access token field.
- Go to Devices, locate ESP32 device, open the device details, and select the Latest telemetry tab.
- It is now possible to view the data regarding an asset.

The data obtained through ThingsBoard is later processed by an intelligent model, the model confirms or denies the existence of a real emergency. This is the reason why configuring the platform is very important.

An association must be created between the different values of the sensors and the corresponding response. Once these associations are created, it is possible to modify any value depending on the values to be tested empirically or in the alarms. Alarms are configured in the device settings so that the respective notifications appear on the panel. A rule chain must be added.

A selection of the attributes placed on the server and on the device's threshold panel must be carried out. The names of the attributes on the server must correspond with those on the panel so that when the data are dynamically configured, they will be recognized correctly and will appear on the diagram generated by the platform, Figure 5.

Subsequently, in the script block, it is verified that the information coming from the device does not exceed the established threshold value. If the script is positive, an alarm is configured and the information to be displayed is defined.

The screenshot shows the ThingsBoard interface. On the left, there is a sidebar with icons for 'Test Device A1' (checkbox), 'B1v2' (checkbox), and 'CINTURON'. Below this is a section titled 'Datos Usuario' (User Data) containing a table of timestamped data for 'B1v2' and 'H1v2' sensors. The table has columns for 'Timestamp' (sorted descending), 'diferenciaAx', and several other numerical columns. On the right, the main area is titled 'B1v2' and 'Detalles del dispositivo'. It includes tabs for 'DETALLES', 'ATRIBUTOS', 'ÚLTIMA TELEMETRÍA', 'ALARMAS' (which is selected and highlighted in orange), 'EVENTOS', 'RELACIONES', and 'REGISTROS DE AUDITORÍA'. Below the tabs, there is a table of alarms with columns for 'Tiempo de creación', 'Origen', 'Tipo', 'Criticalidad', 'Estado', and 'Detalles'. The table lists multiple entries for 'Caida de Usuario' type alarms, all marked as 'Alta' criticality and 'Borrada ignorada' state.

Figure 5. Alarm configuration on ThingsBoard, Block alarm creation method and Connecting alarms with sensors.

Moreover, the root string, which is in charge of obtaining and processing the information coming from the devices, has been modified. In this case, an originator type section has been added, where the devices that transmit the information are identified. Likewise, code strings have been generated to implement the customized code blocks in the panels. Finally, the information on the data panel may be visualized.

In cases where it is not necessary to perform this procedure, it is possible to view the notifications generated by the different devices. To this end, it is necessary to enter the Device section. Select one of the devices for which an alarm has been configured and go to the alarms tab, see Figure 6, where the notifications generated by that device are displayed.

Once the alarms have been configured on the platform, validation is carried out through the explanation of the AI [60].



Figure 6. Final configuration of ThingsBoard platform to be validated through an intelligent algorithm.

4. Platform Evaluation

This section compares the different algorithms used in the state of the art to solve problems similar or related to the one being addressed here [61–64], these models have been accepted for real world problems due to their dataset results with data unbalance and saturation issues, this comparison will be performed with the same amount of data and on an objective quantitative basis. Furthermore, the present proposal is described in detail.

4.1. Data Model

In this study, samples of data from a real environment have been obtained, where a subject was subjected to various scenarios in simulated environments, considering the different risks that could arise. The five analyzed parameters are shown in Table 7. The acquired dataset consists of a total of 11,755 samples, where five descriptive variants are proposed with respect to the target of the study.

Table 7. Parameters for which data are collected.

- 1. Brightness
- 2. Variation in X, Y and Z axis
- 3. Force Sensitive Resistor
- 4. Temperature, Humidity, Pressure
- 5. Air quality

This research tackles a multi-class type of problem, for this reason there is a set of labels that have a different meaning. When the programming of the microcontroller was carried out, the different parameter values that could trigger an alarm signal were investigated, for example, if the air quality falls below the threshold (measured by the Air Quality Index, AQI) it is possible to associate this situation with the values for other parameters measured by neighboring sensors. The 12 labels proposed in this work are described below, where research was carried out on the most common problems in industrial areas and from there the type of sensors in the helmet were included [65,66]:

0. Good for health air (AQI from 0 to 50) with sufficient illumination in the working environment.
1. Moderate air quality (AQI of 51 to 100) with slight variation in temperature and humidity.
2. Harmful air to health for sensitive groups (AQI 101–150) with moderate variation in temperature and humidity.
3. Harmful air to health (AQI 151 to 200) with considerable variation in temperature and humidity.
4. Very harmful air to health (AQI 201 to 300) with high variation in temperature and humidity.
5. Hazardous air (AQI greater than 300) with atypical variation in temperature and humidity.

6. Lack of illumination and variation equivalent to a fall in axes.
7. Lack of illumination and variation equivalent to a fall in axes and considerable force exerted on the helmet.
8. Atypical variation on the detected axes and moderate force detected on the FSR.
9. Illumination problems, air quality and sudden variation in axes.
10. Very high force exerted on the FSR.
11. Variation in axes with illumination problems.
12. Outliers on the 5 sensors.

Once the information has been understood, it is cleaned. As proposed by [67], the data were cleaned due to common problems such as missing values solved with the clamp transformation, see Equation (2).

$$a_i = \begin{cases} lower & \text{if } a_i < lower \\ upper & \text{if } a_i > upper \\ a_i & \text{Otherwise} \end{cases} \quad (2)$$

where a_i represents the i -th sample of the data set, lower and upper thresholds respectively.

The upper and lower thresholds can be calculated from the data. A common way of calculating thresholds for the clamp transformation is to establish:

- The lower threshold value = $Q_1 - 1.5IQR$;
- The upper threshold value = $Q_3 + 1.5IQR$.

Where Q_1 is the first quartile, Q_3 is the third quartile and IQR is the interquartile range ($IQR = Q_3 - Q_1$ the interquartile range). Any value outside these thresholds would become the threshold values. This research takes into account the fact that the variation in a data set may be different on either side of a central trend. Each sample that had missing data was eliminated so as not to bias the model. However, the search for outliers was only used to find erroneous data generated by the electronic acquisition system since outliers usually provide a large source of information for the analysis of a dataset.

4.2. Intelligent Models Evaluation

The comparison part describes each of the models used for the current project, detailing the Support Vector Machine, Naïve Bayes classifier, Static Neural Network and a Convolutional Neural Network. Each model used the dataset of 11,755 where 80% was used for modeling and 20% for evaluation, in other words 9404 in training and 2351 in evaluation. The following confusion matrices reports the result of the validation and after that, we include a figure for each model in order to present the information clearly. It is worth mentioning that all models were trained and validated with the same data division in relation 80-20, it is also notable above an imbalance of classes, given the imbalance some models had unfavorable behavior in cross validation. To handle the imbalance it is possible to opt for techniques such as oversampling or undersampling but it is not desired to change the quality of the data, that is why the model with the best performance will be chosen and evaluated with 10 folds for validation.

Support Vector Machine

SVMs belong to the categories of linear classifiers, since they introduce linear separators better known as hyperplanes, regularly made within a space transformed to the original space.

The first implementation used for the multi-class classification of SVM is probably the one against all method (one-against-all). The SVM is trained with all the examples of the m -th class with positive labels, and all the other examples with negative labels. Therefore, given the data of the $(x_1, y_1), \dots, (x_l, y_l)$ where $x_i \in R^n, i = 1, \dots, l$ y $y_i \in \{1, \dots, k\}$ is the class of x_i , the m -th SVM, and solve

the problem in Equation (3) [68], which involves finding a hyper plane so that points of the same kind are on the same side of the hyperplane, this is finding a b and w such:

$$y_i(w'x_i + b) > 0, \quad i = 1, \dots, N \quad (3)$$

Equation (4) looks for a hyper plane to ensure that the data are linearly separable.

$$\min_{1 \leq i \leq N} y_i(w'x_i + b) \geq 1 \quad (4)$$

where $w \in \mathbb{R}^d$, $b \in \mathbb{R}$ and the training dataset x_i is mapped to a higher dimensional space. Thus, it is possible to search among the various hyperplanes that exist for the one whose distance to the nearest point is the maximum, in other words, the optimum hyperplane [68], see Equation (5).

$$\begin{aligned} \min_{w,b} \frac{1}{2} w^T w \\ \text{individual } a \quad y_i(w^T x_i + b) \geq 1, \forall i \end{aligned} \quad (5)$$

Given the above, we are looking for a plane with the maximum distance between the samples of different classes on a higher dimension. As mentioned above, the SVM was of the type one against all in the mathematical description since it is a multi-class problem. Furthermore, the type of kernel was linear. The modeling was performed and the confusion matrix was obtained with 20% of data for evaluation. The accuracy of each class in comparison to the others can be observed in Table 8. The SVM was the model with the worst performance out of the four evaluated according to the recommendation in the literature where the overall accuracy was 68.51%.

Table 8. Confusion matrix SVM.

Predicted Class (Vertical)/ True Class (Horizontal)	Class 0	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6	Class 7	Class 8	Class 9	Class 10	Class 11
Class 0	153	10	31	0	0	0	0	0	0	1	1	6
Class 1	0	122	0	0	1	6	0	12	0	2	1	5
Class 2	20	0	192	0	0	0	0	0	0	120	0	0
Class 3	20	0	0	158	3	0	13	25	2	101	0	7
Class 4	1	0	0	0	12	0	0	0	3	5	9	0
Class 5	0	25	23	0	0	135	0	0	0	2	8	7
Class 6	0	0	0	0	0	0	110	30	0	1	0	0
Class 7	15	5	30	0	0	57	0	159	0	5	0	0
Class 8	1	9	0	30	0	0	20	0	11	1	0	9
Class 9	13	0	5	40	0	0	10	0	0	432	0	0
Class 10	0	8	0	4	0	0	0	6	0	3	53	0
Class 11	0	0	0	0	0	8	0	0	2	5	72	

Naive Bayes Classifier

A Gaussian NB classifier is proposed that is capable of predicting when an accident has occurred in a work environment through different descriptive characteristics, which is based on Bayes' theorem. Bayes' theorem establishes the following relationship, given the class variable y and the vector of the dependent characteristic x_1 through x_n [69,70], Equation (6).

$$P(y | x_1, \dots, x_n) = \frac{P(y)P(x_1, \dots, x_n | y)}{P(x_1, \dots, x_n)} \quad (6)$$

where $\forall i$, the relationship can be simplified as shown in Equation (7).

$$P(y | x_1, \dots, x_n) = \frac{P(y) \prod_{i=1}^n P(x_i | y)}{P(x_1, \dots, x_n)} \quad (7)$$

where $P(x_1, \dots, x_n)$ is constant based on the input; the classification rule presented in Equation (8) can also be used.

$$\begin{aligned}
 P(y | x_1, \dots, x_n) &\propto P(y) \prod_{i=1}^n P(x_i | y) \\
 &\Downarrow \\
 \hat{y} &= \arg \max_y P(y) \prod_{i=1}^n P(x_i | y),
 \end{aligned} \tag{8}$$

The difference in the distributions of each class in the dataset means that each distribution can be independently estimated as a one-dimensional distribution. This in turn helps reduce the problems associated with high dimensionality. For a Gaussian NB classifier the probability of the characteristics is assumed to be Gaussian, see Equation (9).

$$P(x_i | y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \tag{9}$$

In other words, in order to use the NB classifier in the grouping of the different work circumstances that put the worker at risk, it is assumed that the presence or absence of a particular characteristic is not related to the presence or absence of any other characteristic, given the variable class. The confusion matrix of the NB is shown in Table 9, where on average the accuracy was of 78.26%.

Table 9. Confusion matrix NB.

Predicted Class (Vertical)/True Class (Horizontal)	Class 0	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6	Class 7	Class 8	Class 9	Class 10	Class 11
Class 0	174	10	31	0	1	0	0	0	0	5	1	0
Class 1	0	140	0	0	1	0	0	12	0	2	1	9
Class 2	10	0	220	0	0	0	0	0	0	70	0	0
Class 3	15	0	0	181	0	0	13	5	1	62	0	7
Class 4	1	0	0	0	13	0	0	7	0	1	5	0
Class 5	0	25	13	0	0	155	0	9	0	11	4	1
Class 6	0	0	0	0	0	0	126	1	0	0	0	0
Class 7	9	2	15	0	0	37	0	180	0	0	0	0
Class 8	1	1	0	30	0	0	20	0	13	0	2	4
Class 9	3	0	1	20	1	6	2	18	1	520	0	3
Class 10	0	1	1	1	0	0	0	0	1	0	60	0
Class 11	0	0	0	0	0	0	0	0	3	4	82	

Static Neural Network

Neural networks are simple models of the functioning of the nervous system. The basic units are the neurons, which are usually organized in layers. The processing units are also organized in layers. A neural network normally consists of three parts [71]:

1. An input layer, with units representing the input in the dataset.
2. One or more hidden layers.
3. An output layer, with a unit or units representing the target field or fields.

The units are regularly connected with varying connection forces (or weights). Input data is presented in the first layer, and values are propagated from one neuron to another in the next layer. At the end, a result is sent from the output layer. All the weights assigned to each layer are random in the first instance of the training. However, there are a series of methods that can be employed to optimize this phase. Furthermore, the responses that result from the network are offline. The network learns through training [71]. Data for which the result is known are continuously presented to the network, and the responses it provides are compared with the known results.

The use of a static NN is proposed in this research. The performance of the classic model Adam has been compared with the performance of a CNN. The architecture of the NN is shown in Figure 7, which is a three-layer static model, where the first layer contains five neurons that correspond to each

of the five data being obtained from the multisensory case, the hidden layer has 32 neurons with the ReLU activation function and finally the output layer has 12 neurons representing the situations a worker may find themselves in. They range from safe to risky situations. The last layer has a SoftMax activation function because it is a multi-class problem. The learning step was 0.05 and the model was trained with 500 epochs. In which the approach for the proposed structure is based on “trial and error”, since as it is well known establishing a neural network is more an art than a science. That is why the number of neurons on the second layer was modified, which obtained a better result than adding other layers on the network. However, CNN showed better results than the rest of the models with a predetermined structure (12 neurons in the hidden layer).

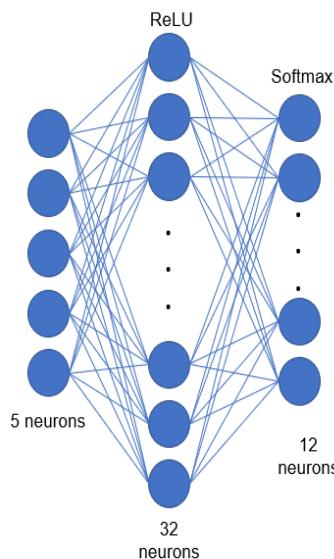


Figure 7. Proposed architecture, static neural network.

The result of the static NN are given in Table 10. It is possible to observe its performance was not very different from the NB classifier, where an average accuracy of 78.56% was obtained.

Table 10. Confusion matrix NN.

Predicted Class (Vertical)/ True Class (Horizontal)	Class 0	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6	Class 7	Class 8	Class 9	Class 10	Class 11
Class 0	175	10	30	0	0	0	0	0	0	5	1	0
Class 1	0	141	0	0	0	0	0	7	0	2	1	9
Class 2	9	0	221	0	0	0	0	0	0	60	0	0
Class 3	13	0	0	181	0	0	13	5	0	50	0	7
Class 4	1	0	0	0	15	0	0	7	0	0	25	0
Class 5	0	23	12	0	0	150	0	9	0	9	9	1
Class 6	0	0	0	0	0	134	1	0	2	0	0	0
Class 7	9	3	16	0	0	32	0	185	0	15	0	0
Class 8	1	1	0	30	0	0	12	0	14	0	2	4
Class 9	3	0	1	20	1	16	2	18	1	526	0	2
Class 10	0	1	1	1	0	0	0	0	1	0	30	0
Class 11	0	0	0	0	0	0	0	0	5	9	83	

4.3. Convolutional Neural Network

A Convolutional Neural Network (CNN) was the selected model, it is a deep learning algorithm mainly used to work with images in which it is possible to use an input image (instead of a single vector as in static NNs), assign importance, weights, learnable biases to various aspects/objects of the image and be able to differentiate one from another [72]. The advantage of NNs is their ability to learn

these filters/characteristics. Given the above we propose the use of a CNN to classify the data coming from the multisensorial helmet.

The proposed CNN's operation is illustrated in Figure 8. The CNN consists of segmenting groups of pixels close to the input image and mathematically operating against a small matrix called a kernel. However, the part of the image is replaced with the input vector of size 5, where a re-shape is made to obtain a vector of 5×1 . Therefore, the kernel proposed in the current CNN is of size 1, and moves from 1×1 pixel, in our case it would be different dimensions. With that size it manages to visualize all the input neurons and thus it can generate a new output matrix; a matrix that will be our new layer of hidden neurons.

A CNN can contain the spatial and temporal dependency characteristics in an image by applying relevant filters, the same applies to a data set that has been re-organized. The proposed architecture is an input layer for the transformed vector with size $5 \times 1 \times 1$ with two hidden convolutional layers for two-dimensional data (Conv2D) and ReLU activation functions with a total of 64 and 32 neurons respectively. Finally a layer with 12 output neurons with SoftMax activation function for multiclass classification.

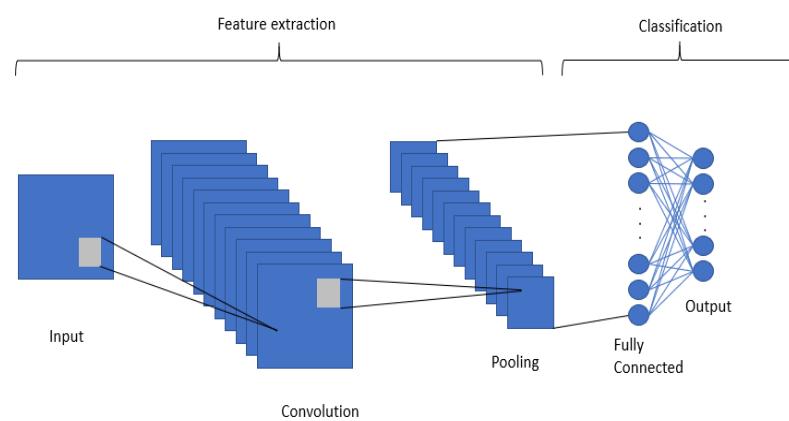


Figure 8. Deep convolutional neural network operation.

A classical model of Adam was proposed and trained with 500 epochs, the parameters were the same for the static NN and CNN to have an objective margin with respect to their evaluation. The following are the results on the AI models used for their implementation in the multisensorial helmet. Table 11 shows the evaluation for CNN where an overall accuracy of 92.05% was achieved.

Table 11. Confusion matrix CNN.

Predicted Class (Vertical)/ True Class (Horizontal)	Class 0	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6	Class 7	Class 8	Class 9	Class 10	Class 11
Class 0	190	0	8	0	0	0	0	0	0	0	0	0
Class 1	8	169	0	0	0	12	0	3	0	0	0	0
Class 2	18	0	267	0	0	3	0	2	0	3	1	0
Class 3	4	0	0	209	0	1	0	0	0	30	0	0
Class 4	1	0	1	0	15	0	0	0	0	0	1	0
Class 5	1	8	0	0	0	179	0	4	0	0	0	0
Class 6	0	2	0	4	0	0	150	0	4	29	0	0
Class 7	1	0	0	0	0	0	0	115	0	0	0	0
Class 8	0	0	0	3	0	0	0	0	67	1	0	0
Class 9	0	0	4	16	0	2	11	1	6	612	0	0
Class 10	0	0	1	0	1	0	0	0	0	1	73	0
Class 11	0	0	0	0	0	1	0	0	0	0	2	106

4.4. Results

As mentioned above, each model was evaluated with 20% of data for cross validation. The SVM presented a general accuracy of 68.51 % which was the model with the lowest performance in cross-validation. Its behavior is compared with that of the rest of the analyzed classes in Figure 9. Therefore, the use of this model in the multisensory helmet has been discarded.

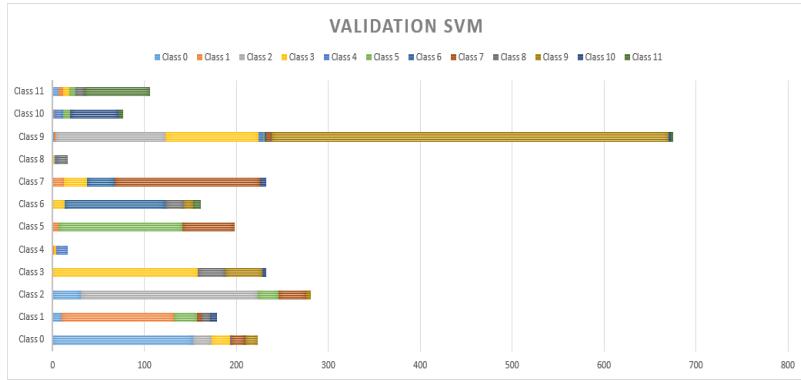


Figure 9. Cross-validation results with 20% for the SVM.

An average accuracy of 78.26% has been achieved by NB in all the classes, as shown in Figure 10. Its performance has been better in class 5 and class 11. Despite having a better result than SVM it has been discarded since there were models that had better performance.

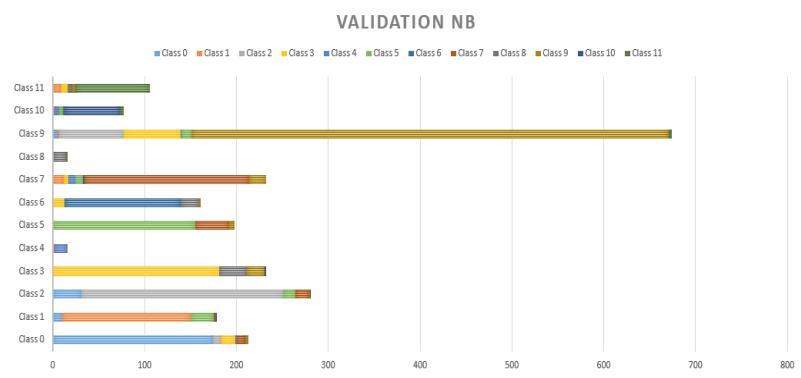


Figure 10. Cross-validation results with 20% for the NB.

Figures 11 and 12 show the performance of static NN and CNN respectively. In Figure 8 it can be observed that there is not a significant difference in the performance of NB, which had an accuracy of 78.56%. On the contrary, CNN, which allows for the implicit extraction of characteristics and for maintaining the relationships between the information regarding the dataset, had a considerably better result, with an accuracy of 92.05%. Our innovation comes on the proposed implementation of a CNN in a safety helmet as a proposal to reduce accidents and fractures in work areas, also through the use of technologies such as IoT for rapid synchronization of alarms that are sent to supervisors to take immediate action.

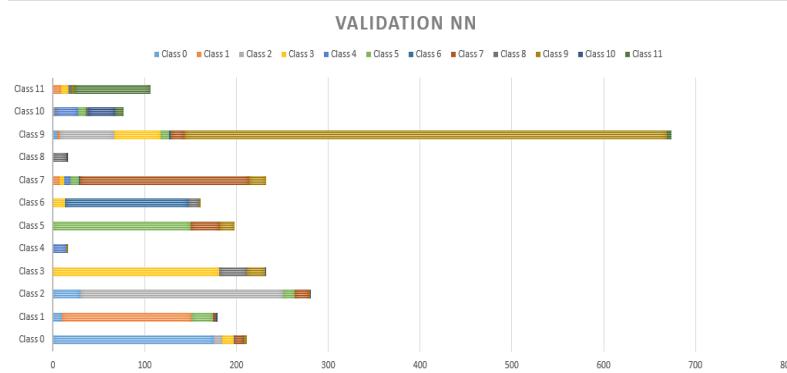


Figure 11. Cross-validation results with 20% for the NN.

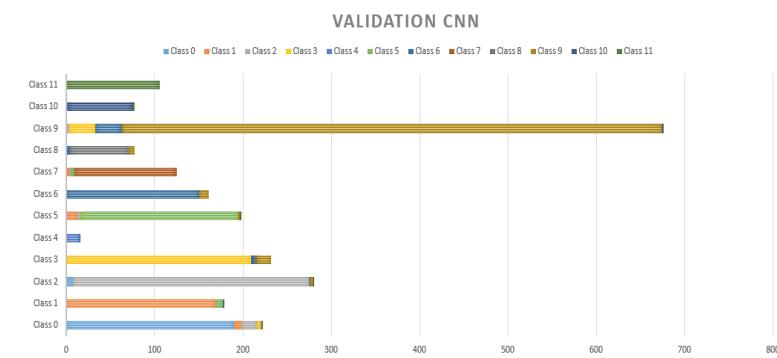


Figure 12. Cross-validation results with 20% for the CNN.

Given the above, CNN is the model that has been implemented in conjunction with the ThingsBoard platform. ThingsBoard and CNN work independently, creating an alarm system in a simulated environment that can serve as a higher security approach to a work environment. CNN is in charge of validating the information obtained from the platform, see Figure 13.

Previously it was mentioned that the creation of the deep models was through the “trial and error” approach, but the possible problem of overfitting should not be left aside, that is why Table 12 shows the results for the CNN in 10-Folds that shows the average performance from an objective point of view of the models.

Table 12. Ten-fold validation for CNN.

Ten Fold Cross-Validation Test Sets	Accuracy (%) (Automated Risk Situations Develop in This Research)
1	93.18
2	93.09
3	90.73
4	94.12
5	91.27
6	92.75
7	92.61
8	92.59
9	92.76
10	91.99
Average Accuracy	92.509

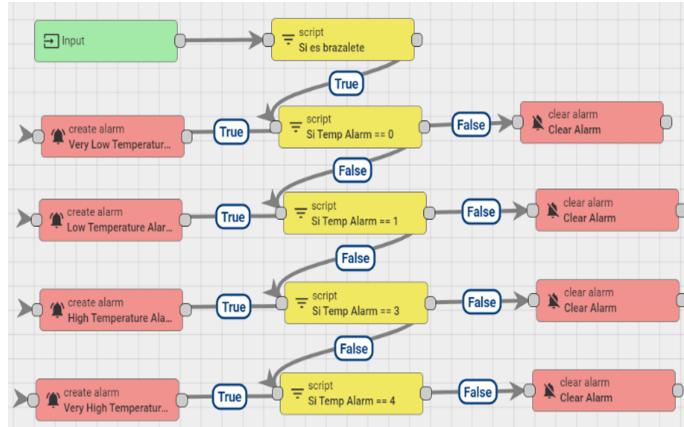


Figure 13. System of alarm rules established in ThingsBoard.

In the next section, the conclusions drawn from the conducted research are described, and the contributions of this work to the state of the art are highlighted.

5. Conclusions and Discussion

Our work has a history of electronic development in which the use of a multisensory helmet was established. Through a conditional model of input–output rules, we tried to detect the different situations to which a worker was subjected. However, the input–output techniques presented false positives and false negatives with 60% accuracy in the best of cases, which is why after several stages, it was decided to implement AI in the helmet. The 60% that was described a moment ago is due to the combination of different circumstances, that is to say, the correlation that exists on the independent characteristics, is for that reason, that through techniques that find linear and nonlinear relations we decided to innovate in the present work. Since it is necessary to find the patterns that determine a particular action, for them there are the techniques of deep learning as our work presents

The comparison between different models of AI has been made in this research. Our innovation comes from the moment of using a CNN that in the literature has been used to analyze images or videos in intelligent helmets with the aim of saving lives. However, we proposed a multisensory approach to real-time feature analysis. Through the transmission of data through specialized IoT devices, a smart helmet has been designed to monitor the conditions in a working environment. The application areas of this proposal are industrial and agricultural sectors and any other sector that involves risk for the workers. Thanks to the helmet, different injuries can be avoided, and in case an accident occurs the damage caused to the worker is lessened through prompt attention or detection.

It is possible to observe in Figures 9–11 that the MSA presented many false positives on majority classes in sample size, and even false positives of repeated classes (class 6) on more than five different classifications. NB and NN had a better performance in minority classes, however, there are three different classifications in false positives in classes such as 11, 9, 7, 2, 1 and 0. The NN has a strong resolution where the classes mentioned above still present false positives but with a decrease to 2 wrong classes in almost all cases.

5.1. Limitations

The work has different limitations. It is well known that artificial intelligence has the ability to find patterns that can hardly be found in linear analysis models. However, as stated in [73] risk analyses are not yet common in project-oriented industries. A problem with current risk analysis procedures is that procedures that are simple enough to be used by normal project staff are too simplistic to capture the

subtlety of risk situations. Those that are complex enough to capture the essence and subtlety of risk situations are so complex that they require an expert to operate them. That is why the combination of possible risk situations can be counterproductive in the industrial area, an area that should be analyzed in more detail, with the following consequences:

- False positives would result in economic losses that would eventually affect the services and production areas involved, since the medical service and will be attending to situations that were not risky, the industry part will have to make production stops every time a false positive is found.
- On the other hand, false negatives are even more dangerous because the misinterpretation of data due to the complexity that can cause the unbalance of classes with less data set would result in losses not only economic but also of human personnel due to situations that were not attended to in the indicated time.

Our system has limitations on the amount of data that can be processed due to the microcontroller and the data that the model supports through the ESP32 module. That is why other techniques can be adopted, as will be seen in the next part of future work.

5.2. Future Work Opportunities

The use of paradigms such as edge computing or fog computing for the processing of many data as would be the integration of images or video would be the viable option to allow a transmission of information in real time, avoiding problems of saturation by the microcontroller. Several state-of-the-art researches have proposed smart helmets, among them is the US6798392B2 patent [74], which integrates a global location system, an environmental interaction sensor, a mobile communications network device, a small display panel, a microphone and a speaker. The helmet knows the location of the user and their interaction with the environment. The helmet can provide data to a user, monitor the actions of the user and conditions. This work is quite interesting since it offers device–user interaction. On the contrary, the advantage of our proposal is that it strives towards the autonomy of the system where decisions are made by the convolutional method.

Furthermore, the US9389677B2 patent [75], which is a smart helmet that includes a camera, a communications subsystem and a control subsystem. The control subsystem processes the video data from the camera, and the communications subsystem transmits this video data from the smart helmet to a target device. This work can be taken as a reference for a future sensor integration, since in our proposal it would be possible to integrate a camera that can process data through Deep CNN, for example thermal radiation data or even data regarding those who are infected with COVID-19.

Furthermore, the US registered patent, US20150130945A1 [76], in which a smart helmet is proposed that includes a helmet shell, a visor and a projector mounted on the helmet shell. The projector is configured so that content can be selected for display on the visor. The visor is rotatably attached to the helmet shell, and is configured to expose or cover the passage. The hull of the helmet defines an internal cavity and a passage that communicates with the internal cavity. The internal cavity is designed to receive the head of a user. This proposal's focus is directed at the ergonomic part for the user, in addition to having navigation systems and control modules. This research is comparable to our proposal.

Moreover, in 2013 a helmet was proposed by Rasli Mohd Khairul Afiq Mohd et al. [77] for the prevention of accidents in which an FSR and a BLDC fan were used to detect the head of the driver and the speed of the motorcycle, respectively. A 315 MHz radio frequency module was used as a wireless link for communication between the transmitter circuit and the receiver circuit. PIC16F84a is a microcontroller for the control of the different components of the system. The motorcyclist could start the engine only when they had fastened their helmet. In comparison, our proposal communication takes place through IIoT for optimized decision making in case of accidents.

With reference to smart helmets connected to IoT, in 2016 [78], Sreenithy Chandran et al. presented a design whose objective is to provide a channel and a device for monitoring and reporting accidents.

Sensors, a Wi-Fi enabled processor, and cloud computing infrastructures were used to build the system. The accident detection system communicates the accelerometer values to the processor that continuously monitors erratic variations. When an accident occurs, details about the accident are sent to emergency contacts using a cloud-based service. The location of the vehicle is obtained using the global positioning system. This work has a close relationship with the one proposed by us where there is optimized communication to reduce the consequences of accidents, the approach is different since we propose it for a work environment that can later be adapted for a case focused on vehicle safety, mainly on motorcycles.

Author Contributions: I.C.-J. data cleaning, analysis and modeling; S.M.-S. in electronic design; J.Q.-G. firmware programming and IIoT communications management, S.R. in data interpretation analysis, J.M.C. in supervision and direction of the entire project. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by Research group in Bioinformatics, Intelligent Computer Systems and Educational Technology (BISITE), R&B building, Calle Espejo s/n, 37008, Salamanca, Spain.

Acknowledgments: Thanks are due to the entire BISITE research group for their invaluable work from electronic design to management for information analysis. Likewise, for providing the economic resources to make this work possible.

Conflicts of Interest: The authors declare no conflict of interest. Each of the researchers and scientists who have developed the current work presents no conflict of interest with respect to the design of the study; in the collection, analyses or interpretation of data; in the writing of the manuscript, or in the decision to publish the results

Abbreviations

The following abbreviations are used in this manuscript sorted alphabetically:

AI	Artificial Intelligence
AQI	Air Quality Index
ARCTM	Accident Root Causes Tracing Model
CM	Condition Monitoring
CNN/ConvNet	Convolutional Neural Network
EEG	Electroencephalographic
GMM	Gaussian Mixture Model
ICTs	Information and communication technologies
IIoT	Industrial Internet of Things
IITEM	Internet of Things for Equipment Maintenance
JSA	Job Safety Analysis
KC	K-means Clustering
LAN	Local Area Networks
LCC	Latent Class Clustering
LP	License Plate
MEMS	Micro-Electromechanical System
ML	Machine Learning
MNL	Multinomial Logit
NB	Naive Bayes Classifier
NN	Neural Network
NNC	Nearest Neighbor Classification
OHS	Occupational Health and Safety
PPE	Personal Protective Equipment
RF	Random Forests
SVM	Support Vector Machine
UKF	Unscented Kalman Filter
VOC	Volatile Organic Compounds

References

1. Formación Superior en Prevención de Riesgos Laborales. Parte Obligatoria y Común. Available online: <http://www.paraprofesionales.com/indices/ind50276.pdf> (accessed on 1 November 2020).
2. Seguridad e Higiene Industrial. Available online: <http://168.121.45.184/bitstream/handle/20.500.11818/599/Seguridad%20e%20Higiene%20Industrial-1-79.pdf?sequence=1&isAllowed=y> (accessed on 1 November 2020).
3. Chevalier, Y.; Compagna, L.; Cuellar, J.; Drielsma, P.H.; Mantovani, J.; Mödersheim, S.; Vigneron, L. A High Level Protocol Specification Language for Industrial Security-Sensitive Protocols. Available online: <https://hal.inria.fr/inria-00099882/document> (accessed on 1 November 2020).
4. Vaughn, R.B., Jr.; Henning, R.; Fox, K. An empirical study of industrial security-engineering practices. *J. Syst. Softw.* **2002**, *61*, 225–232. [CrossRef]
5. Varian, H. *Artificial Intelligence, Economics, and Industrial Organization*; Technical Report; National Bureau of Economic Research: Cambridge, MA, USA, 2018.
6. Lee, J.; Davari, H.; Singh, J.; Pandhare, V. Industrial Artificial Intelligence for industry 4.0-based manufacturing systems. *Manuf. Lett.* **2018**, *18*, 20–23. [CrossRef]
7. Li, B.H.; Hou, B.C.; Yu, W.T.; Lu, X.B.; Yang, C.W. Applications of artificial intelligence in intelligent manufacturing: A review. *Front. Inf. Technol. Electron. Eng.* **2017**, *18*, 86–96. [CrossRef]
8. Cockburn, D. Artificial Intelligence System for Industrial Applications. *Found. Distrib. Artif. Intell.* **1996**, *9*, 319.
9. Chamoso, P.; González-Briones, A.; Rodríguez, S.; Corchado, J.M. Tendencies of technologies and platforms in smart cities: A state-of-the-art review. *Wirel. Commun. Mob. Comput.* **2018**, *2018*, 3086854. [CrossRef]
10. Sun, S.; Zheng, X.; Gong, B.; García Paredes, J.; Ordieres-Meré, J. Healthy Operator 4.0: A Human Cyber-Physical System Architecture for Smart Workplaces. *Sensors* **2020**, *20*, 2011. [CrossRef]
11. Podgorski, D.; Majchrzycka, K.; Dąbrowska, A.; Gralewicz, G.; Okrasa, M. Towards a conceptual framework of OSH risk management in smart working environments based on smart PPE, ambient intelligence and the Internet of Things technologies. *Int. J. Occup. Saf. Ergon.* **2017**, *23*, 1–20. [CrossRef]
12. Fernández-Muñiz, B.; Montes-Peón, J.M.; Vázquez-Ordás, C.J. Safety climate in OHSAS 18001-certified organisations: Antecedents and consequences of safety behaviour. *Accid. Anal. Prev.* **2012**, *45*, 745–758. [CrossRef]
13. Niu, Y.; Lu, W.; Xue, F.; Liu, D.; Chen, K.; Fang, D.; Anumba, C. Towards the “third wave”: An SCO-enabled occupational health and safety management system for construction. *Saf. Sci.* **2019**, *111*, 213–223. [CrossRef]
14. Barata, J.; da Cunha, P.R. The Viable Smart Product Model: Designing Products that Undergo Disruptive Transformations. *Cybern. Syst.* **2019**, *50*, 629–655. [CrossRef]
15. Kumar, S.G.; Dharianipriya, A. Prevalence and pattern of occupational injuries at workplace among welders in coastal south India. *Indian J. Occup. Environ. Med.* **2014**, *18*, 135. [CrossRef]
16. Yedula, N.R.; Koolmees, D.S.; Battista, E.B.; Raza, S.S.; Montgomery, Z.A.; Day, C.S. *Upper-Extremity Injuries Are the 2nd Most Common Workplace Injuries from 1992 to 2018*; Wayne State University: Detroit, MI, USA, 2020.
17. Champoux, D.; Brun, J.P. Occupational health and safety management in small size enterprises: an overview of the situation and avenues for intervention and research. *Saf. Sci.* **2003**, *41*, 301–318. [CrossRef]
18. Hasle, P.; Limborg, H.J. A review of the literature on preventive occupational health and safety activities in small enterprises. *Ind. Health* **2006**, *44*, 6–12. [CrossRef] [PubMed]
19. Hasle, P.; Limborg, H.J.; Granerud, L. Social responsibility as an intermediary for health and safety in small firms. *Int. J. Workplace Health Manag.* **2011**, *4*, 109–122.
20. Henley, E.J.; Kumamoto, H. *Designing for Reliability and Safety Control*; Prentice Hall: Upper Saddle River, NJ, USA, 1985.
21. Han, Y.; Song, Y. Condition monitoring techniques for electrical equipment-a literature survey. *IEEE Trans. Power Deliv.* **2003**, *18*, 4–13. [CrossRef]
22. Glendon, A.I.; Litherland, D.K. Safety climate factors, group differences and safety behaviour in road construction. *Saf. Sci.* **2001**, *39*, 157–188. [CrossRef]
23. Xiaoli, X.; Yunbo, Z.; Guoxin, W. Design of intelligent internet of things for equipment maintenance. In Proceedings of the 2011 Fourth International Conference on Intelligent Computation Technology and Automation, Shenzhen, China, 28–29 March 2011; Volume 2, pp. 509–511.

24. Casado-Vara, R.; Chamoso, P.; De la Prieta, F.; Prieto, J.; Corchado, J.M. Non-linear adaptive closed-loop control system for improved efficiency in IoT-blockchain management. *Inf. Fusion* **2019**, *49*, 227–239. [[CrossRef](#)]
25. Casado-Vara, R.; González-Briones, A.; Prieto, J.; Corchado, J.M. Smart contract for monitoring and control of logistics activities: pharmaceutical utilities case study. In *The 13th International Conference on Soft Computing Models in Industrial and Environmental Applications*; Springer: Berlin/Heidelberg, Germany, 2018; pp. 509–517.
26. Abdelhamid, T.S.; Everett, J.G. Identifying root causes of construction accidents. *J. Constr. Eng. Manag.* **2000**, *126*, 52–60. [[CrossRef](#)]
27. Cambraia, F.B.; Saurin, T.A.; Formoso, C.T. Identification, analysis and dissemination of information on near misses: A case study in the construction industry. *Saf. Sci.* **2010**, *48*, 91–99. [[CrossRef](#)]
28. Cheng, T.; Teizer, J. Real-time resource location data collection and visualization technology for construction safety and activity monitoring applications. *Autom. Constr.* **2013**, *34*, 3–15. [[CrossRef](#)]
29. Chi, S.; Han, S. Analyses of systems theory for construction accident prevention with specific reference to OSHA accident reports. *Int. J. Proj. Manag.* **2013**, *31*, 1027–1041. [[CrossRef](#)]
30. Choudhry, R.M.; Fang, D. Why operatives engage in unsafe work behavior: Investigating factors on construction sites. *Saf. Sci.* **2008**, *46*, 566–584. [[CrossRef](#)]
31. Fitton, D.; Sundramoorthy, V.; Kortuem, G.; Brown, J.; Efstratiou, C.; Finney, J.; Davies, N. Exploring the design of pay-per-use objects in the construction domain. In *European Conference on Smart Sensing and Context*; Springer: Berlin/Heidelberg, Germany, 2008; pp. 192–205.
32. Godfrey, A.; Conway, R.; Meagher, D.; ÓLaighin, G. Direct measurement of human movement by accelerometry. *Med Eng. Phys.* **2008**, *30*, 1364–1386. [[CrossRef](#)] [[PubMed](#)]
33. Ohtaki, Y.; Sagawa, K.; Inooka, H. A method for gait analysis in a daily living environment by body-mounted instruments. *JSME Int. J. Ser. C Mech. Syst. Mach. Elem. Manuf.* **2001**, *44*, 1125–1132. [[CrossRef](#)]
34. Zampella, F.; Khider, M.; Robertson, P.; Jiménez, A. Unscented kalman filter and magnetic angular rate update (maru) for an improved pedestrian dead-reckoning. In Proceedings of the 2012 IEEE/ION Position, Location and Navigation Symposium, Myrtle Beach, SC, USA, 23–26 April 2012; pp. 129–139.
35. Zhou, Y.; Jing, L.; Wang, J.; Cheng, Z. Analysis and selection of features for gesture recognition based on a micro wearable device. *Int. J. Adv. Comput. Sci. Appl.* **2012**, *3*, 15–24. [[CrossRef](#)]
36. Zhu, C.; Sheng, W. Human daily activity recognition in robot-assisted living using multi-sensor fusion. In Proceedings of the 2009 IEEE International Conference on Robotics and Automation, Kobe, Japan, 12–17 May 2009; pp. 2154–2159.
37. Otis, M.J.D.; Menelas, B.A.J. Toward an augmented shoe for preventing falls related to physical conditions of the soil. In Proceedings of the 2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Seoul, Korea, 14–17 October 2012; pp. 3281–3285.
38. Yu, H.; Shi, L.C.; Lu, B.L. Vigilance estimation based on EEG signals. In Proceedings of the IEEE/ICME International Conference on Complex Medical Engineering (CME2007), Beijing, China, 23–27 May 2007.
39. Lindeman, R.W.; Yanagida, Y.; Noma, H.; Hosaka, K. Wearable vibrotactile systems for virtual contact and information display. *Virtual Real.* **2006**, *9*, 203–213. [[CrossRef](#)]
40. Cao, T.; Wan, F.; Wong, C.M.; da Cruz, J.N.; Hu, Y. Objective evaluation of fatigue by EEG spectral analysis in steady-state visual evoked potential-based brain-computer interfaces. *Biomed. Eng. Online* **2014**, *13*, 28. [[CrossRef](#)]
41. Qiang, C.; Ji-Ping, S.; Zhe, Z.; Fan, Z. ZigBee based intelligent helmet for coal miners. In Proceedings of the 2009 WRI World Congress on Computer Science and Information Engineering, Los Angeles, CA, USA, 31 March–2 April 2009; Volume 3, pp. 433–435.
42. Nithya, T.; Ezak, M.M.; Kumar, K.R.; Vignesh, V.; Vimala, D. Rescue and protection system for underground mine workers based on Zigbee. *Int. J. Recent Res. Asp.* **2018**, *4*, 194–197.
43. Kim, S.H.; Wang, C.; Min, S.D.; Lee, S.H. Safety Helmet Wearing Management System for Construction Workers Using Three-Axis Accelerometer Sensor. *Appl. Sci.* **2018**, *8*, 2400. [[CrossRef](#)]
44. Fang, Y.; Cho, Y.K.; Chen, J. A framework for real-time pro-active safety assistance for mobile crane lifting operations. *Autom. Constr.* **2016**, *72*, 367–379. [[CrossRef](#)]
45. Li, P.; Meziane, R.; Otis, M.J.D.; Ezzaidi, H.; Cardou, P. A Smart Safety Helmet using IMU and EEG sensors for worker fatigue detection. In Proceedings of the 2014 IEEE International Symposium on Robotic and Sensors Environments (ROSE) Proceedings, Timisoara, Romania, 16–18 October 2014; pp. 55–60.

46. Wahab, L.; Jiang, H. A comparative study on machine learning based algorithms for prediction of motorcycle crash severity. *PLoS ONE* **2019**, *14*, e0214966. [[CrossRef](#)]
47. Bleser, G.; Damen, D.; Behera, A.; Hendeby, G.; Mura, K.; Miezal, M.; Gee, A.; Petersen, N.; Maçães, G.; Domingues, H.; et al. Cognitive learning, monitoring and assistance of industrial workflows using egocentric sensor networks. *PLoS ONE* **2015**, *10*, e0127769. [[CrossRef](#)] [[PubMed](#)]
48. Yogameena, B.; Menaka, K.; Perumaal, S.S. Deep learning-based helmet wear analysis of a motorcycle rider for intelligent surveillance system. *IET Intell. Transp. Syst.* **2019**, *13*, 1190–1198. [[CrossRef](#)]
49. Iranitalab, A.; Khattak, A. Comparison of four statistical and machine learning methods for crash severity prediction. *Accid. Anal. Prev.* **2017**, *108*, 27–36. [[CrossRef](#)] [[PubMed](#)]
50. Pal, M. Random forest classifier for remote sensing classification. *Int. J. Remote Sens.* **2005**, *26*, 217–222. [[CrossRef](#)]
51. Rodriguez-Galiano, V.F.; Ghimire, B.; Rogan, J.; Chica-Olmo, M.; Rigol-Sánchez, J.P. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS J. Photogramm. Remote Sens.* **2012**, *67*, 93–104. [[CrossRef](#)]
52. Azar, A.T.; Elshazly, H.I.; Hassani, A.E.; Elkorany, A.M. A random forest classifier for lymph diseases. *Comput. Methods Programs Biomed.* **2014**, *113*, 465–473. [[CrossRef](#)]
53. Belgiu, M.; Drăguț, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* **2016**, *114*, 24–31. [[CrossRef](#)]
54. Jedari, E.; Wu, Z.; Rashidzadeh, R.; Saif, M. Wi-Fi based indoor location positioning employing random forest classifier. In Proceedings of the 2015 International Conference on Indoor Positioning and Indoor Navigation (IPIN), Banff, AB, Canada, 13–16 October 2015; pp. 1–5.
55. Khalilia, M.; Chakraborty, S.; Popescu, M. Predicting disease risks from highly imbalanced data using random forest. *BMC Med. Inform. Decis. Mak.* **2011**, *11*, 51. [[CrossRef](#)]
56. Shine, L.; Jiji, C.V. Automated detection of helmet on motorcyclists from traffic surveillance videos: A comparative analysis using hand-crafted features and CNN. *Multimed. Tools Appl.* **2020**, *79*, 14179–14199. [[CrossRef](#)]
57. Li, T.C.; Su, J.Y.; Liu, W.; Corchado, J.M. Approximate Gaussian conjugacy: Parametric recursive filtering under nonlinearity, multimodality, uncertainty, and constraint, and beyond. *Front. Inf. Technol. Electron. Eng.* **2017**, *18*, 1913–1939. [[CrossRef](#)]
58. Raj, K.D.; Chairat, A.; Timtong, V.; Dailey, M.N.; Ekpanyapong, M. Helmet violation processing using deep learning. In Proceedings of the 2018 International Workshop on Advanced Image Technology (IWAIT), Chiang Mai, Thailand, 7–9 January 2018; pp. 1–4.
59. Albrechtsen, E.; Solberg, I.; Svensli, E. The application and benefits of job safety analysis. *Saf. Sci.* **2019**, *113*, 425–437. [[CrossRef](#)]
60. González-Briones, A.; Chamoso, P.; Yoe, H.; Corchado, J.M. GreenVMAS: Virtual organization based platform for heating greenhouses using waste energy from power plants. *Sensors* **2018**, *18*, 861. [[CrossRef](#)] [[PubMed](#)]
61. Ali, M.S. A. Helmet deduction using image processing. *Indones. J. Electr. Eng. Comput. Sci.* **2018**, *9*, 342–344. [[CrossRef](#)]
62. Preetham, D.A.; Rohit, M.S.; Ghontale, A.G.; Priyadarsini, M.J.P. Safety helmet with alcohol detection and theft control for bikers. In Proceedings of the 2017 International Conference on Intelligent Sustainable Systems (ICISS), Palladam, India, 7–8 December 2017; pp. 668–673.
63. Bisio, I.; Fedeli, A.; Lavagetto, F.; Pastorino, M.; Randazzo, A.; Sciarrone, A.; Tavanti, E. Mobile smart helmet for brain stroke early detection through neural network-based signals analysis. In Proceedings of the GLOBECOM 2017–2017 IEEE Global Communications Conference, Singapore, 4–8 December 2017; pp. 1–6.
64. Dasgupta, M.; Bandyopadhyay, O.; Chatterji, S. Automated Helmet Detection for Multiple Motorcycle Riders using CNN. In Proceedings of the 2019 IEEE Conference on Information and Communication Technology, Allahabad, India, 6–8 December 2019; pp. 1–4.
65. Cauvin, S.; Cordier, M.O.; Dousson, C.; Laborie, P.; Lévy, F.; Montmain, J.; Porcheron, M.; Servet, I.; Travé-Massuyès, L. Monitoring and alarm interpretation in industrial environments. *AI Commun.* **1998**, *11*, 139–173.

66. Gryllias, K.C.; Antoniadis, I.A. A Support Vector Machine approach based on physical model training for rolling element bearing fault detection in industrial environments. *Eng. Appl. Artif. Intell.* **2012**, *25*, 326–344. [[CrossRef](#)]
67. Kelleher, J.D.; Mac Namee, B.; D'arcy, A. *Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies*; MIT Press: Cambridge, MA, USA, 2015.
68. Suykens, J.A.; Vandewalle, J. Least squares support vector machine classifiers. *Neural Process. Lett.* **1999**, *9*, 293–300. [[CrossRef](#)]
69. An empirical study of the naive Bayes classifier. In *IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence*. Available online: <https://www.semanticscholar.org/paper/An-empirical-study-of-the-naive-Bayes-classifier-Watson/2825733f97124013e8841b3f8a0f5bd4ee4af88a> (accessed on 1 November 2020).
70. D'Agostini, G. *A Multidimensional Unfolding Method Based on Bayes' Theorem*; Technical Report, P00024378; INFN: Roma, Italy, 1994.
71. Hassoun, M.H. *Fundamentals of Artificial Neural Networks*; MIT Press: Cambridge, MA, USA, 1995.
72. Kalchbrenner, N.; Grefenstette, E.; Blunsom, P. A convolutional neural network for modelling sentences. *arXiv* **2014**, arXiv:1404.2188.
73. Diekmann, J.E. Risk analysis: Lessons from artificial intelligence. *Int. J. Proj. Manag.* **1992**, *10*, 75–80. [[CrossRef](#)]
74. Hartwell, P.G.; Brug, J.A. Smart Helmet. U.S. Patent 6,798,392, 28 September 2004.
75. Hobby, K.C.; Gowing, B.; Matt, D.P. Smart Helmet. U.S. Patent 9,389,677, 12 July 2016
76. Yu, C.C.; Chu, B.H.; Chien, H.W. Smart Helmet. U.S. Patent Application 14/539,040, 14 May 2015.
77. Rasli, M.K.A.M.; Madzhi, N.K.; Johari, J. Smart helmet with sensors for accident prevention. In Proceedings of the 2013 International Conference on Electrical, Electronics and System Engineering (ICEESE), Kuala Lumpur, Malaysia, 4–5 December 2013; pp. 21–26.
78. Chandran, S.; Chandrasekar, S.; Elizabeth, N.E. Konnect: An Internet of Things (IoT) based smart helmet for accident detection and notification. In Proceedings of the 2016 IEEE Annual India Conference (INDICON), Bangalore, India, 16–18 December 2016; pp. 1–4.

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

4.2. BeSafe B2. 0 Smart Multisensory Platform for Safety in Workplaces

4.2.1. Información de la publicación

Título: BeSafe B2. 0 Smart Multisensory Platform for Safety in Workplaces

Autores: Sergio Márquez Sánchez^{a,b}, Israel Campero Jurado^c, Daniel Robles Camarillo^d, Sara Rodríguez González^a, Juan Manuel Corchado Rodríguez^{a,b,e,f}.

Afiliaciones:

^a BISITE Research Group, University of Salamanca, Edificio I+D+i, C/ Espejo, Salamanca 37007, Spain.

^b Air Institute, IoT Digital Innovation Hub (Spain), 37188 Salamanca, Spain

^c Department of Mathematics and Computer Science, Eindhoven University of Technology, 5600MB Eindhoven, The Netherlands

^d Graduate School in Information Technology and Communications Research Department, Universidad Politécnica de Pachuca, Zempoala Hidalgo 43830, Mexico.

^e Department of Electronics, Information and Communication, Faculty of Engineering, Osaka Institute of Technology, Osaka 535-8585, Japan

^f Faculty of Creative Technology & Heritage, Universiti Malaysia Kelantan, Locked Bag 01, 16300 Bachok, Malaysia **Publicado en:** *Sensors 2021, 21(10), 3372. Special Issue Knowledge Transfer in IoT and Edge Computing*)

D.O.I.: <https://doi.org/10.3390/s21103372>

Fecha de publicación: 12 Mayo 2021.

Factor de Impacto: 3.576 – Q1 (2020)

4.2.2. Introducción

Cada vez son más los accesorios o equipos de seguridad destinados a mejorar las condiciones de los trabajadores en diferentes sectores. Muchas empresas han aumentado su inversión en el desarrollo de este tipo de herramientas, especialmente aquellas cuyos trabajadores deben realizar actividades extenuantes o que implican un alto nivel de riesgo (Bensel & Santee, 2006; Podgorski et al., 2017). Las personas que trabajan en

entornos, como la minería o emplazamientos industriales, están expuestas a diferentes condiciones a su alrededor, muchas de las cuales pueden ser perjudiciales para su salud. Por ejemplo, puede haber un alto riesgo de sufrir lesiones traumáticas, que es un problema al que siempre se le ha dado mucha importancia, dado que este tipo de lesiones pueden ser mortales. Asimismo, otros factores que desencadenan situaciones de vulnerabilidad pueden estar relacionados con el trabajo o con la responsabilidad de terceros. Existen también riesgos laborales asociados a la fatiga y el estrés, hechos que causan una gran preocupación.

La innovación de este estudio radica en la promoción de la seguridad en el lugar de trabajo, mediante la creación de un entorno inteligente en el que el uso de datos, inteligencia artificial y algoritmos, permita anticiparse a los riesgos emergentes y proporcionar ayuda en situaciones inusuales. Para ello, se ha generado un brazalete que integra electrónica avanzada en el textil, que hace que el tejido adquiera una mayor funcionalidad y el sistema pueda captar y enviar la información obtenida de la monitorización, y al mismo tiempo pueda interactuar con el trabajador. Gracias a esta integración se favorece el uso por parte del usuario, ya que se mimetiza con el de una forma cómoda, sin que suponga un problema en su trabajo diario.

El producto deeptech desarrollado es una plataforma AIoT (Artificial Intelligent IoT) que combina estrategias de Inteligencia Artificial e Internet de las Cosas para la adquisición de datos en tiempo real con el fin de generar conocimiento valioso. En la versión 1 de BeSafe, se había presentado una plataforma basada en reglas a través de árboles de decisión (Campero-Jurado et al., 2020). Sin embargo, no se habían encontrado relaciones que mostraran un comportamiento lineal, por lo que en esta versión se propone analizar los conjuntos de datos adquiridos por los sensores de la pulsera implementando el reconocimiento de la actividad humana combinada con otros dispositivos y algoritmos de aprendizaje no supervisado para la detección de anomalías. Esto nos permite aprovechar el concepto de AIoT y ofrecer soluciones innovadoras al usuario.

Las plataformas actuales centran sus esfuerzos en la productividad y encontramos pocos ejemplos que adopten sistemas de monitorización del entorno o del propio trabajador. Además, estas están diseñadas para casos muy concretos o muy generales y poco adaptables a las industrias. En este sentido, la plataforma BeSafe 2.0 busca dar servicio a la industria conectada, siendo capaz de integrar diferentes dispositivos

de protección individual, que puedan interconectarse entre sí y que posteriormente se permita una visualización en tiempo real y detección temprana de cualquier anomalía. Hoy en día, se requiere recoger datos de muy diferentes fuentes de forma fiable y unificada en el ámbito industrial, transformando la información, reduciendo los tiempos y costes de desarrollo (Bokor, 2012; Dong & Srivastava, 2013). La plataforma incorpora algoritmos de fusión y procesos de minería de datos de los diferentes dispositivos conectados y una base de conocimiento para innovar y reducir el impacto de cualquier anomalía para construir un sistema Smart Data, capaz de dar respuestas inteligentes. Se ha utilizado una metodología compuesta por algoritmos adaptados a la información obtenida, proporcionando una base de conocimiento para la predicción de anomalías que aporta gran valor (Rodríguez et al., 2015). La plataforma incorpora el uso de redes neuronales, lógica difusa, redes bayesianas, árboles de decisión y otras técnicas híbridas de inferencia e inteligencia artificial (Bajo, De Paz, Villarrubia, & Corchado, 2015), que proporcionarán una visión resumida del gran volumen de datos del que se quiere obtener información.

Por todo lo anterior, la motivación del trabajo es proveer a través de las Tecnologías de la Información (TICs), junto con la Inteligencia Artificial (IA) y dispositivos con electrónica wearable, de la identificación de anomalías en la información recogida a través de diferentes sensores especializados. Atendiendo a los objetivos específicos (OB3), (OB5) y (OB6) definidos en el Capítulo 1. Para ello el presente trabajo propone el uso de un brazalete inteligente multisensorial con el cuál transmitir la información para la toma de decisiones y la detección de anomalías.

4.2.3. Objetivos

El trabajo publicado se enmarca dentro de las diferentes investigaciones y experimentaciones que se han llevado a cabo en cuanto al diseño e implementación de nuevos dispositivos basados en tecnologías de textiles electrónicos y tecnología wearable, combinadas con el uso de Inteligencia Artificial, así como la experimentación y validación de dichos mecanismos en laboratorio. En este sentido, tal y como queda definido en los Objetivos Específicos en el Capítulo 1, en esta publicación se asignaron los siguientes objetivos:

- Investigar el diseño de nuevas herramientas y soluciones para la monitorización y protección de las personas en su entorno de trabajo, basadas en electrónica wearable y tejidos inteligentes, para su incorporación en EPIs.
- Investigar sobre técnicas y metodologías sobre el tratamiento de los datos recogidos en los sensores. Uso de análisis de datos, algoritmos de prevención y el uso de la plataforma de control.
- Diseñar la evolución de la arquitectura AIoT, mediante una nueva versión que proporcione funcionalidades.
- Integrar las prestaciones que proporciona el AIoT y Smart Data para obtener una plataforma de apoyo en el desempeño de la actividad, capaz de evolucionar y aprender.

4.2.4. Conclusiones

Las mejoras presentadas en este trabajo han consistido en la incorporación de nuevos materiales y funciones en el equipo de protección previamente desarrollado y en una plataforma centralizada mejorada, que ofrece servicios de asistencia y visualización. Junto con el brazalete, las características de la plataforma generan un sistema muy valioso para la prevención de riesgos y la anticipación médica-sanitaria. Las innovaciones tecnológicas de la AIoT introducidas por plataforma y brazalete, permiten monitorizar aspectos que afectan a la salud de los trabajadores y proporcionan información sobre los parámetros físicos, con el reconocimiento de la actividad humana. También se analiza el entorno utilizando la capacidad que proporciona el Smart Data para detectar situaciones que puedan provocar enfermedades laborales. Para el reconocimiento de la actividad humana (HAR) en el trabajo se ha optado por utilizar una IMU BMI160 con el cual realizar la recogida de datos y posteriormente utilizar Mezclas Gaussianas (GMM) y Long short-term memory network (LSTM) como modelos para la Clasificación de la Actividad Humana.

En el presente trabajo se han utilizado cuatro etiquetas para representar diferentes situaciones. El GMM permitió separarlas y etiquetar las que no entran dentro de una distribución normal de forma multivariada. En el GMM, tenemos regularmente asociaciones de los datos en cada grupo, y también podemos identificar la separación de

las muestras que caen en un rango de normalidad, como en el enfoque de optimización de K-Means. A diferencia de K-Means, los clusters no se identifican por un diámetro definido, sino que los grupos se adaptan a una distribución, lo que permite reducir el número de falsos positivos e identificar situaciones reales de riesgo para los usuarios de pulseras. El GMM permite identificar los datos que indican un peligro, aunque los grupos se solapen, esto es así porque identifica los patrones que definen cada una de las etiquetas. El aprendizaje adaptativo del sistema, le permite categorizar los datos de forma independiente a través de la monitorización en tiempo real. A diferencia de otras propuestas del estado del arte y patentes registradas, no establecemos la clasificación de etiquetas. Nos centramos en encontrar valores críticos en las muestras para aumentar el porcentaje de verdaderos positivos y falsos positivos.

Los dispositivos integran una gran variedad de sensores que garantizan la seguridad del usuario en su día a día y que permiten al usuario interactuar con la plataforma, monitorizar sus parámetros y medir las condiciones del entorno. Además, la investigación propone la inclusión de sensores que trabajen conjuntamente, orientados principalmente a detectar parámetros que impliquen un riesgo o una anomalía para el usuario. Además, gracias a su sensor de frecuencia cardíaca se intenta evitar posibles accidentes causados por paros cardíacos o desmayos por altas temperaturas corporales.

La plataforma, con su enfoque modular, posibilita su integración en diferentes industrias para la identificación anomalías y la alerta a los responsables o unidades de emergencia, donde su mayor fortaleza es el uso de aprendizaje profundo en el reconocimiento de la actividad humana.

4.2.5. Publicación original



Article

BeSafe B2.0 Smart Multisensory Platform for Safety in Workplaces

Sergio Márquez-Sánchez ^{1,2,*†}, Israel Campero-Jurado ^{3,†}, Daniel Robles-Camarillo ⁴ and Sara Rodríguez ¹
and Juan M. Corchado-Rodríguez ^{1,2,5,6}

¹ BISITE Research Group, University of Salamanca, Calle Espejo s/n. Edificio Multiusos I+D+i, 37007 Salamanca, Spain; srg@usal.es (S.R.); corchado@usal.es (J.M.C.-R.)

² Air Institute, IoT Digital Innovation Hub (Spain), 37188 Salamanca, Spain

³ Department of Mathematics and Computer Science, Eindhoven University of Technology, 5600MB Eindhoven, The Netherlands; i.campero.jurado@tue.nl

⁴ Graduate School in Information Technology and Communications Research Department, Universidad Politécnica de Pachuca, Zempoala Hidalgo 43830, Mexico; danielrc@upp.edu.mx

⁵ Department of Electronics, Information and Communication, Faculty of Engineering, Osaka Institute of Technology, Osaka 535-8585, Japan

⁶ Faculty of Creative Technology & Heritage, Universiti Malaysia Kelantan, Locked Bag 01, Bachok, Kota Bharu 16300, Kelantan, Malaysia

* Correspondence: smarquez@usal.es; Tel.: +34-685-043-554

† These authors contributed equally to this work.



Citation: Márquez-Sánchez, S.; Campero-Jurado, I.; Robles-Camarillo, D.; Rodríguez, S.; Corchado-Rodríguez, J.M. BeSafe B2.0 Smart Multisensory Platform for Safety in Workplaces. *Sensors* **2021**, *21*, 3372. <https://doi.org/10.3390/s21103372>

Academic Editor: Celimuge Wu and Francesco Meraldo

Received: 29 March 2021

Accepted: 2 May 2021

Published: 12 May 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: Wearable technologies are becoming a profitable means of monitoring a person's health state, such as heart rate and physical activity. The use of the smartwatch is becoming consolidated, not only as a novelty but also as a very useful tool for daily use. In addition, other devices, such as helmets or belts, are beneficial for monitoring workers and the early detection of any anomaly. They can provide valuable information, especially in work environments, where they help reduce the rate of accidents and occupational diseases, which makes them powerful Personal Protective Equipment (PPE). The constant monitoring of the worker's health can be done in real-time, through temperature, falls, noise, impacts, or heart rate meters, activating an audible and vibrating alarm when an anomaly is detected. The gathered information is transmitted to a server in charge of collecting and processing it. In the first place, this paper provides an exhaustive review of the state of the art on works related to electronics for human activity behavior. After that, a smart multisensory bracelet, combined with other devices, developed a control platform that can improve operators' security in the working environment. Artificial Intelligence and the Internet of Things (AIoT) bring together the information to improve safety on construction sites, power stations, power lines, etc. Real-time and historic data is used to monitor operators' health and a hybrid system between Gaussian Mixture Model and Human Activity Classification. That is, our contribution is also founded on the use of two machine learning models, one based on unsupervised learning and the other one supervised. Where the GMM gave us a performance of 80%, 85%, 70%, and 80% for the 4 classes classified in real time, the LSTM obtained a result under the confusion matrix of 0.769, 0.892, and 0.921 for the carrying-displacing, falls, and walking-standing activities, respectively. This information was sent in real time through the platform that has been used to analyze and process the data in an alarm system.

Keywords: AIoT; Gaussian mixture model; smart bracelet; anomaly detection; artificial intelligence; smart PPE; machine learning; deeptech; human activity classification

1. Introduction and Motivation

There is growing an amount of accessories and safety equipment designated to improve environmental conditions for workers in different sectors. Many companies have

increased their investment in developing such settings, especially those whose employees must perform strenuous or risky activities [1,2].

People who work in areas, such as mining or industrial locations, are exposed to different conditions which may have a detrimental impact on their health. For example, there may be a high risk of suffering traumatic injuries, a problem that has always been given considerable importance, given that this type of injuries may be fatal.

The innovation of this study lies in promoting safety in the workplace, by creating an intelligent environment in which the use of data, artificial intelligence, and algorithms, makes the anticipation of emerging risks possible and provides assistance in anomalous situations. Our contributions include:

1. The development of wearable hardware for receiving different vital and environmental signals from specific workers or users.
2. A hybrid integration; a model based on anomaly detection and time series analysis.
3. The connection of artificial intelligence models and wearable devices to a platform for data reception and emission of alerts.

Regarding Machine Learning models, our objective was to present a combination of models on the basis of supervised and unsupervised learning in order to decrease the classification noise, since we trained a model (which is explained later on) of time series with all the data from the wearable device; however, due to the nature of the information, our performance in evaluation was little more than 60%, which is why we decided to split the present work.

BeSafe B2.0 also includes the integration of advanced electronics in textile, this technology is sometimes referred to as “electronic textiles” that causes the fabric to acquire greater functionality; through electronics, the system can capture and send the information obtained from monitoring; moreover, the user can interact with the material. The integration of electronics in the fabric favors its use because it can be worn comfortably, as a bracelet, and does not interfere with the everyday work of the user or employee.

The developed deeptech product is an AIoT (Artificial Intelligent IoT) platform that combines Artificial Intelligence and Internet of Things strategies with real-time data acquisition to generate valuable knowledge. In the first version of BeSafe [3], a platform based on rules through decision trees had been presented. However, no relationships displaying linear behavior had been found; for this reason, this research focuses on the analysis of the datasets acquired by the sensors in the bracelet, implementing human activity recognition combined with other unsupervised learning algorithms to detect anomalies. This allows us to take advantage of the concept of AIoT and offer innovative solutions to the user. The devices integrate a wide variety of sensors that ensure the user's safety on a daily basis. These sensors measure parameters that imply a risk or an anomaly for the user. Regarding the electronics, different technologies are integrated to enable the user to interact with the platform and monitor their parameters, as well as measure the conditions in the surrounding environment. Currently, this bracelet can be produced on demand, and its development can be adapted to the needs of the target user.

The latest data (from 2019), provided by the Spanish national institute of social security statistics, showed that the number of occupational accidents with sick leave was 650,602 out of a total of 19.75 million workers, while the number of accidents without sick leave was 724,321. Among the accidents with sick leave, 3542 were serious incidents, and 489 were fatal accidents [4]. Depending on the work environment, there are greater or lesser risks which must be carefully analyzed [3,5,6]. Some professions involve the performance of high-risk tasks, where there is a possibility of lethal accidents occurring. However, other factors that trigger discomfort among workers: vibration [7], exposure to the sun, temperature, gas or noise, also introduce risk in the work environment. Other factors that make workers vulnerable include work-related or third party liability. There are occupational risks associated with fatigue and stress, and this is certainly of concern.

The state-of-the-art platforms focus on increasing productivity, but few on monitoring the environment or the worker. Moreover, these are designed for either very specific

or very general cases, and do not adapt well to the needs of industries. In this regard, our platform meets the needs of connected industry by making it possible to integrate different individual protection devices, which allows for real-time visualization and for the early detection of any anomaly. Currently, data collection has become a requirement for industries as it enables the reduction of times and costs [8,9]. Thus, ensuring the integration, security and quality of the data coming from very heterogeneous sources is essential [10,11]. The platform incorporates fusion algorithms and data mining processes of the different connected devices and a knowledge base to reduce the impact of any anomaly, comprising a Smart Data system capable of providing intelligent responses [10]. It uses a methodology composed of algorithms adapted to the obtained information, offering a knowledge base for predicting anomalies that provide great value [12]. The platform incorporates the use of neural networks, fuzzy logic, Bayesian networks, decision trees, and other hybrid inference and artificial intelligence techniques [13], which extract key information from large volumes of data. The platform incorporates virtual organizations responsible for the fusion of information from the data sources of multiple domains. When linked together, they further facilitate the performance of a complete analysis.

Human activity recognition (HAR) has attracted the attention of the scientific community because it provides personalized support in different applications since the 1980s, and it has been studied extensively in the last decade. Depending on the purpose of the application, contiguous portions of data streams are used to detect and classify human behavior, preprocessing them transforms the raw signal data into feature vectors. The range of cell phone applications is massive [14], especially in health monitoring, which can be associated with a context and tracked. Some of the most notable examples are detecting movement, when a person is walking or running [15–17], tracking emotional state [18], or classifying patterns in sleep and exercise [19]. In this regard, BMI160 IMU has been chosen for data collection, while Gaussian Mixtures, through long-term memory, have been used as a model for the classification of human activity.

Thus, it is extremely important to provide increasingly robust devices capable of identifying anomalies on the basis of the information read by specialized sensors. All this can be achieved through Information and Communication Technologies, together with Artificial Intelligence and electronics.

This research proposes the detection of anomalies through a multisensorial intelligent bracelet so that information can be collected and transmitted for decision-making. This proposal has been implemented in a real environment, as detailed further in this work. As it is a wearable device, the user's behavior can be analyzed. Among its capabilities, it can measure parameters, such as pulse and temperature, and detect falls or accidents. It sends alerts whenever an anomaly is detected in the environment, thanks to an intelligent platform that provides total support to the operator and other workers.

The remainder of this work is organized as follows: Section 2 describes an overview of the related literature. Section 3 details the system design. In Section 4, we present the electronic system based on a multisensor bracelet where we apply short term memory (LSTM) through the Gaussian mixture model (GMM) and the transmission of information. Thanks to these, it is possible to detect anomalies with the use of a dataset and the implementation of a model for the classification of human activity. Finally, in the last section, we present some conclusive remarks and future lines of research.

2. State of the Art

Over the last decade, platforms implementing predictive maintenance strategies have been introduced on the market [20–24]. These solutions monitor machines through the capture of data by sensors, making it possible to maximize the availability of the machines involved in industrial processes, increasing the efficiency of the maintenance process. The emergence of technologies, such as BigData, has also favored the processing of real-time data, to which data mining techniques can be applied in large-scale industrial processes [25]. Another current trend in this type of platforms is to use cloud architectures

to process large amounts of data, offering solutions that are framed in software, platform and infrastructure. This type of architecture, combined with virtual organizations of agents, allows the platform to be modular and scalable, facilitating the incorporation of new vertical solutions integrated in the platform's horizontal design [26,27]. In addition, with the use of technologies, such as edge computing, it is possible to propose environments capable of processing information close to the device, which makes it possible to manage data more efficiently and rationally [28], many of these platforms are based on models with rule structures, where depending on certain conditions decisions can be made about the information being processed in the cloud. However, our proposal is extended by integrating two artificial intelligence models that work together to mitigate false alarm errors. The use of the different enabling technologies of Industry 4.0 has led to the creation of new platforms and to the improvement in the quality of the obtained information. Industry 4.0 platforms are able to process data and understand their meaning; a feature that can revolutionize today's industries, as the majority of current platforms do not apply these new technologies [29–32]. Recently, relevant research studies have been conducted in the area of smartwatch wearables, for instance, to prevent the spread of COVID-19, as well as to identify the disease at a much earlier stage, reduce death rate, and monitor the user's body temperature, heart rate, and blood pressure [33]. Other studies propose other smartwatch functionalities, apart from parameter measurement. For example, the research of Adjiski Vancho et al. involved the development of an architecture that can be used in underground mining and that uses sensors attached to regular PPE clothing, including hard hats and safety glasses. These sensors are connected to the smartphone and smartwatch via Bluetooth low energy sensors, to provide real-time safety, situational awareness, and predict health and safety incidents before they occur [34].

Regarding the safety of workers and creating a safe working environment, wearable devices have captured the attention of industries and the academic community. This fact is evidenced by the growing tendency of organizations towards the research and development of these products, due to the multiple fields in which they can be useful: sports, security, health, entertainment, etc. There have been several advances and proposals in the field of electronic systems, which focused on the ability to monitor users' vital signs. Among those proposals is patent USD535205S1 [35], made in the United States and invented by Walter H. Frederick et al., with a clock design, as shown in Figure 1.

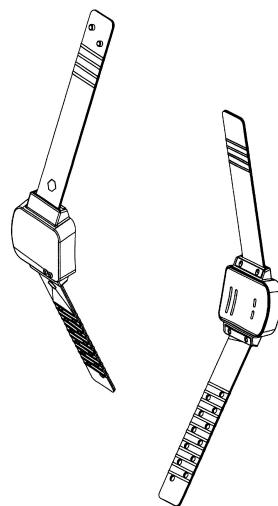


Figure 1. Patent watch/bracelet form USD535205S1 [35].

Another patent registered in the United States was the device US20170027511A1 invented by Robert A. Connor [36]. The patent is currently active, this gadget is a device that can be carried on the arm with adjusted bio-metric sensors. These can be spectroscopic sensors that project light onto the surface of the arm at different angles. Alternatively, these sensors can be electromagnetic energy sensors that measure the impedance, resistance, conductivity or permittivity of tissues. One of the main approaches of this patent is to measure the levels of oxygen, glucose, hydration, and even the heart rate of the individual; that is, this patent focuses on the vital signs of the person, where the proposed design is included in a general way. Our aim is to focus on a tool for the environment that workers are in, i.e., analyzing changes in user behavior to detect problems, such as falls, as this has always been a problem in industrial companies.

Finally, the U.S. patent, US20190064792A1, invented by Charles Howard Cella et al., is a monitoring and surveillance system for implementation in a data collection environment. It operates through the Internet of Industrial Things (IIoT) with intelligent data management for industrial processes, including an analog sensor. A data collector can be added to this system and coupled with multiple analog sensors. Likewise, the data storage and data analysis circuit's structure enables it to analyze the collected data and select a plan from among numerous data collection management plans, to later analyze the received data and decision management for actuators. This work is quite similar to ours; however, we focus on real-time analysis for immediate decision-making, as our goal is to reduce response time when there has been a fallout from industrial staff or the environmental issues that compromises workers' health.

In September 2016, Michele Magno et al. [37] presented the design and implementation of a sensor-based, energy-collecting smart bracelet called InfiniTime, which also underwent field evaluation. The system has a wearable design, and it integrates temperature sensors and an accelerometer, as well as an ultra-low power camera and a microphone. The purpose of the bracelet is self-sustainability by using solar cells with modest levels of indoor light and thermoelectric generators (TEG) with body heat temperature gradients.

In November 2013, Martin Ouwerkerk et al. [38] developed a wireless sensor bracelet, its design based on the knowledge gained from a predecessor sensor bracelet, and the authors gave reasons for the sensors they had chosen. The disadvantage they present is the battery performance of the product software, which did not last 7 working days; therefore, they addressed it through software optimization, which meets the design objective of battery life. In addition, in March 2015, Giancarlo Fortino et al. [39] proposed C-SPINE, a framework for collaborative social security networks (CBSN), where collaboration is based on interaction and synchronization between CBSNs and collaborative distributed computing over collaborating CBSNs. CBSNs are body sensor networks (BSNs) that have the ability to interact and support each other to perform a task. To demonstrate their effectiveness, they implemented e-Shake, a CBSN collaborative system for detecting emotions. This system must acquire multisensor data to perform automatic detection. Regarding the power consumption of our device, we have adapted it to be as low as possible (which will be explained, together with the other hardware details, in Section 3).

In 2017, Singh Ericet et al. [40], addressed graphene-based materials and their possible applications in flexible and extendable wearable electronic devices, where graphene is one of the nanomaterials with a broad variety of uses. In addition, it has other implicit properties that make it suitable for use in fields, such as cancer detection or chemical detection. Moreover, the authors discussed the role of graphene in the manufacture of flexible gas sensors for the detection of various hazardous gases; this type of sensor could be considered in a future research to improve the current proposal. In November 2015, several transparent and stretchable sensors (TS) with high optical transparency were introduced by Trung Tran Quang et al. [41]. The TS gate sensor array has a high response to temperature changes occurring in objects and the human skin. Since the emergence of this technology, a growing amount of highly compatible devices have been developed to be worn and used

by specific users. This work showed the applicability of the TS gate sensor array in skin electronics for the recognition of human activity.

Concerning the parameters that can be measured by this type of device, we should highlight GPS, for the location of the user carrying the Smartwatch [42–45]. In other cases, triangulation [46] offers a more precise system which is used by dementia patients to improve their living conditions [47]. Research has also been done on measuring heart rate [48], and some studies in literature employ an optical sensor for heart rate monitoring [49–51]. Other studies deal with the monitoring of heart frequency, using a technique called photoplethysmography [52–54], thanks to which, from a beam of light, the volume of the determined organ can be measured, and, in the majority of cases, it is used to calculate the amount of oxygen in the blood.

Human Activity Recognition (HAR) has become of great interest in several sectors, including PRL. Its development is favored by the development of multisensor systems, which use a combination of inertial measurement units (IMUs) on the body. The aim is to identify and detect activities; however, this is a complex task as the data is ambiguous or noisy. Therefore, Machine Learning-based models are required to learn from the data to extract knowledge and detect and classify behavioral patterns [55–57]. Numerous works exploring the use of techniques that focus on Naive Bayes (NB) [58], Decision Trees [59], Hidden Markov Modeling (HMM) [60], Neural Networks (NN) [61], Support Vector Machines (SVM) [62], and Deep Belief Networks (DBN) [63] are some of the most relevant implementations. Another noteworthy application is the use of a three-axis accelerometer, which, helped by an algorithm, can detect the number of steps taken and monitor the user's physical activity [45–47,49] and even detect falls [53], epileptic seizures [43], and degrees of shaking that happen to people with Parkinson's disease [64]. It is remarkable to know that thanks to the combination of accelerometers, gyroscopes (IMUs) and algorithms, we can reach a high precision [50,65], as demonstrated in the Smartwatch Pebble which used the CUSUM algorithm [66] and advanced sorting and filtering techniques from Kalman for the subsequent detection of falls, using an accelerometer, a gyroscope, and contact sensors to perform an initial evaluation. In addition, to filter out the noise and avoid errors [46], the Moving Average Filter (MAF) was used.

There are intelligent algorithms capable of gathering the data, analyzing it, and deciding whether it is a false positive, an expected value or whether an emergency is occurring, thanks to the prior programming of the data monitored. Minimum and maximum values are programmed, and, if we are in between them, it means that the patient's condition is normal. It is essential to highlight that this algorithm learns; that is, if the system alerts of an abnormality that is later assessed by the doctor as a false positive, the algorithm would not make that mistake again. When it has accumulated 48 measurements, it sends a report to the doctor about the user's condition [51]. Another example of data collection and analysis is the Rapid Miner [67] or the use of an expert system, such as KBS, capable of making decisions and taking action in cases where the patient exceeds the established thresholds [48]. In terms of monitoring the psychological state of the user, we find Smart Personal Health Advisor (SPHA) architectures [45] which provide the user with a personalized life guide to their daily activities and interaction with their environment. For monitoring purposes, smart textiles are used to collect the user's physiological data, with sensors to measure the electrocardiogram, temperature and the amount of oxygen in the blood.

Regarding the noise that can be generated in an environment, in September 2004, an active noise cancellation methodology, using a MEMS accelerometer to recover the signals from the sensors that have been corrupted due to body movement, was proposed by Asada H. Harry et al. [68]. The procedure was proposed for a finger ring photoplethysmogram (PPG) sensor, in which the signal is susceptible to the movement of the wearer's hand. The purpose was to recover the corrupted PPG signal. The positive or negative relationship between the acceleration and the distorted PPG signal is analyzed, and a low-order Finite Impulse Response (FIR) model is obtained that relates the signal distortion to the hand acceleration.

Regarding artificial intelligence models, in 2009, Reynolds [69] presented the main characteristics of the GMM, which is a parametric probability density function represented as a weighted sum of the densities of the Gaussian components. Other investigations have also been carried out on the same AI model [45,70,71]. This model has been widely used to detect anomalies due to its ideal characteristics [45,72–74]; therefore, in the present paper, it will be used to find alterations in the data that have to be in a certain distribution in order to detect possible problems in a work environment where the short- or long-term risk of suffering an accident, disorder, or fracture is high [75–80].

Among the wearable products, we find many commercial products that allow to monitor vital signs and enable interaction, such as SmartWatch (Apple Watch Series 5, Xiaomi mi band 4, Amazfit, Huawei Smartwatch, Samsung galaxy watch 2, etc.). Their technological features with a wide variety of sensors and functions make them very attractive for daily use. They can help us in areas, such as health monitoring, by sending notifications on training completion, goal setting, sleep monitoring, heart rate monitoring, all-day heart rate review, resting heart rate, heart rate table, and inactivity alerts. We can also use them in our training or use other features. They offer stopwatches as alarms and phone notifications, incoming calls, message and calendar notifications, application notifications, weather forecast, find the phone, unlock the phone, and event notification. In terms of sensing, they have a GPS, a heart rate sensor, an accelerometer, a gyro, a magnetic sensor, a pressure sensor, an ambient light sensor, a capacitive sensor, NFC, LTE, Wi-Fi, and others [5,6,81,82].

E. C. Nelson et al. (2016) [83] demonstrated, through a survey in which data was collected on the internet, that people can influence their motivation and actions if they commit to the self-observation of their activity. The theory further postulates that the gathered self-diagnostic information has an important self-motivating function and gives people the ability to set goals for objective improvement and gives them the feeling that they can regulate those goals themselves. Thus, the success of self-regulation depends partially on the fidelity, consistency and temporal proximity of self-monitoring [84]. If we bring this result to the work environment, the worker may feel more confident in performing their tasks while wearing the bracelet, which may even improve the quality of their work and health. K. J. Kim et al. (2015) [85] examine several psychological factors closely associated with wearing technology and explain how these factors contribute to determining the user acceptance of smartwatches by integrating them with the technology acceptance model (TAM), one of the most widely used theoretical models for studying end-user acceptance of ICTs. The investigations that propose wrist bands with wearable monitoring and sensor networks are compiled in Table 1.

Table 1. Proposals related to wearable monitoring and sensor networks in a wrist band.

Bibliography	Sensors Included	Advantages and Disadvantages	Novelty of the Proposal
Shin, D. M. et al. (2013).	GPS, ambient light sensor, accelerometer, wireless communications	It stands out for including GPS and implementing location-based positioning.	It is an intelligent surveillance system, for the use and improvement of living conditions of patients with dementia.
Perez, M. N. et al. (2015).	Optical heart rate sensor, accelerometer, a capacitive sensor, and thermistor	It measures activities, such as exercise and sleep quality, that have not been considered in our work.	Monitor the user's daily activities, including exercise, sleep quality, heartbeat and food types
Shin, D. et al. (2014).	GPS, ambient light sensor, accelerometer, wireless communications	The work is focused on dementia and includes positioning. It also highlights the algorithm for fall detection.	The main purpose of the bracelet is to prevent dementia patients from getting lost and to detect falls.
Sendra, S. et al. (2018).	Accelerometer, microphone, heart rate, and blood oxygen sensor with photoplethysmography, GPS, elastic band to measure breathing and thermometer	It is focused on disease measurement and incorporates sensors not considered in our article.	Control of chronic diseases of children with remote monitoring constantly with the help of remote devices.
Chen, M. et al. (2018).	Electrocardiogram, temperature and the amount of oxygen in the blood	It measures oxygen in the blood, a sensor that has not been considered in our work.	Monitoring the psychological state of the user using Smart Personal Health Advisor (SPHA) systems
Kajornkasirat, S. et al. (2018).	Heart rate sensor, vibrator, audio support, connection via Bluetooth	Aspects of daily life are detected but no accidents or anomalies.	Counts the steps, the calories burned, monitors our sleep, and analyzes the calories we eat at lunch
Maglogiannis, I. et al. (2014).	Accelerometer, gyroscope and contact sensors, vibrator, magnetometer, ambient light sensor and Bluetooth 4.0	Falls are detected with the CUSUM algorithm and we detect the falls through the IMU itself.	Initial evaluation of fall detection using the CUSUM algorithm
Alsulami, M. H. et al. (2016).	Heart rate sensor	Heart rate is monitored with an expert system called KBS. In our case we extend this to other variables.	The use of smart watches to monitor heart rate in older people using expert system called KBS capable of making decisions and taking action.
Karakaya, M. et al. (2017).	Accelerometer and gyroscope	It only uses an IMU with a KNN classifier as a sensor, so our proposal is more complete	Remote monitoring of elderly people's activities using Smart Watch using a KNN classifier
Reeder, B. et al. (2016).	Gyroscope, microphones, optical heart rate sensor, contact sensor for temperature measurement and light sensor for sun exposure	Very comprehensive review in which several sensors not covered in our work are used.	Systematic review of the uses of intelligent surveillance for health and well-being with different watch models

Table 1. Cont.

Bibliography	Sensors Included	Advantages and Disadvantages	Novelty of the Proposal
Nguyen, D. N. et al. (2017).	Shock sensor, microphone, pulse sensor, temperature sensor and GPS	Detection of parameters for anomaly detection using a microphone as an extra to our work.	Smart Watch with automatic voice recording and alarm
Parara, A., & Sekka, S. (2016).	Heart rate sensor, GPS, touch screen and microphone	A system including positioning and a microphone as additional components is presented.	Intelligent user care security surveillance device
Mukhopadhyay, S. C. (2014).	Body temperature sensor, heart rate meter with photoplethysmography (PPG), microphone, camera, accelerometer, and electrocardiogram	It focuses on Human Behavior Activity and is not aimed at alarm detection.	Review of wearable sensors for monitoring human activity
Gope, C. (2015).	Accelerometer, GPS, panic button	It is aimed at the detection of epileptic movements and does not cover other areas of interest in our case.	Smart Watch for surveillance and monitoring of seizures / abnormal movement activities or epileptic seizures.
Wile, D. J. et al. (2014).	Accelerometer	It is aimed at tremor analysis and does not cover other areas of interest in our case.	Smart Watch accelerometry for tremor analysis and diagnosis
Kumari, P. et al. (2017)	Electroencephalogram (EEG), electrooculogram (EOG), electromyography (EMG), electrocardiogram (ECG)	This is similar work that focuses on aspects of monitoring people rather than detecting alarms caused by accidents.	Review of wearables and multimodal interface for human activity monitoring
Manisha, M. et al. (2016)	Heart rate and blood pressure sensor	The application is heart attack detection. So it only uses sensors aimed at detecting heart attacks.	Device targeting heart disease, monitoring heartbeats and blood pressure, to try to reduce the number of deaths due to heart attacks
Dhull, R. et al. (2020)	Failure of respiratory system of human, body temperature, heart rate, and blood pressure.	The smartwatch is used for COVID detection and the sensors it implements and its software are closed to this application.	Discuss the design, principle of operation and features of different smartwatches
Adjiski, V. et al. (2019)	Accelerometer, gyroscope, magnetometer, and heart rate sensor	It is dedicated to mining and the smartwatch does not implement fall detection.	Real-time safety situation awareness and predict health and safety incidents before they occur

The novelty of the proposed solution lies in its holistic approach. It uses artificial intelligence models combined with wearable electronics and IoT devices to provide it with greater capabilities than the solutions developed until now, creating a much more favorable environment for the personal protection of workers. Compared to other state-of-the-art developments, the novelty of this proposal is the development of a new wearable device for the measurement of different vital and environmental signals from specific workers or users. In addition to the ability to connect the bracelets to the platform, it is also possible to integrate other devices that provide the system with complementary information. These devices can be used in different environments, thus achieving a modular design that is valid for the different problems we may encounter in different work environments. Another novelty of this research is the union of artificial intelligence models and wearable devices in a hybrid platform, offering data reception and alarm generation functionalities through the hybrid integration of model-based anomaly detection and time series analysis. Regarding Machine Learning models, our objective was to present an union of models based on supervised and unsupervised learning, in order to decrease the classification noise since we trained a model of time series (which will be explained later) including all the data from the wearable devices; however, due to the nature of the information, our performance in evaluation was little more than 60%, which is why we decided to split the present work.

3. The BeSafe Platform

The main objective of this investigation is the presentation of a platform to improve the safety of operators' in their work environment, and it involves research into information and communication systems equipped with ambient intelligence. Due to previous research, this product is already at stage 2 of development, and is being developed further in the current study. Changes have been made in terms of ergonomics, speed of receiving information and safety, and previous versions have been referenced [81].

To develop this platform, the requirements have been specified, and the architecture has been defined to identify the most common risk situations and generalize them, achieving the greatest possible impact through a limited set of actions. Given the large amount of information on this topic, an analysis has been carried out of the recommendations that appear in the regulations and risk prevention manuals, with the aim of identifying the risks that could be feasibly covered, given their compatibility with the developed device. On this basis, the functionalities to be incorporated in the proposed solution have been defined, as well as the technical aspects of the device implementation, such as the design of an architecture, the definition of the components and the connectors, and the correct identification of the flow of information through the different modules. Using the formalization of the model, the rules for associating the risks with a set of preventive measures have been created, given the context of the situation.

Version 2.0 has been completed after carrying out the evaluation process, resulting in a control and visualization platform in which hybrid artificial intelligence algorithms are integrated for the detection and prevention of risks and accidents. As part of platform development, algorithms have been designed for decision-making and for the identification of risk situations and the identification of these scenarios in the database, so that the worker can be notified.

The last phase sought to integrate and validate the system in a simulated environment by deploying the platform and interconnecting it with the bracelet, helmet and belt, checking that the developed functionalities met the requirements specified in the first phase of the project with the corresponding advantages provided by the use of data analysis, prevention algorithms and the use of the control platform. The functional solution has been validated in different work environments, where its correct performance has been evaluated.

The research process has demanded the application of different agile methodologies that ensured the obtained results would be aligned with the initial objectives. Starting

with the collection, organization, and the subsequent analysis of the information, so a time frame is set for the achievement of intermediate stages, and a metric system is established to evaluate the results.

3.1. BeSafe B2.0 Platform Design

The prototype that is being sought is a bracelet with a wide variety of sensors that increase the users' safety in daily life. Its key objective is to detect anomalies or any situation that may put the user at risk. To this end, a review has been carried out of the different technologies available on the market in the field of interaction and monitoring of both the user and the environment as shown in Table 2.

Table 2. Identification of common risk situations in the worker's environment and electronic components.

Risk Factors	Associated Hazards	Solution
Heart rate	- Heart attack and irregular heartbeat	- Wearing a heart rate sensor on the wrist
Temperature	- Extreme temperature changes leading to a heat stroke - Unhealthy temperature for work that may indicate fever or hypothermia	- Implementation of temperature sensors in the bracelet
Operator Movement	- Slips, trips and falls - Blows to the worker's hand	- The use of IMU capable of detecting falls or impacts - Integration of sensitive force resistors in the bracelet of the operator.
Reporting an accident	- Falls, intoxication, fire, collapse, heart attack, loss of consciousness, among others.	- Resistive touch pad

Below are all the technologies that have been chosen for implementation, as shown in Figure 2 and Table 3.

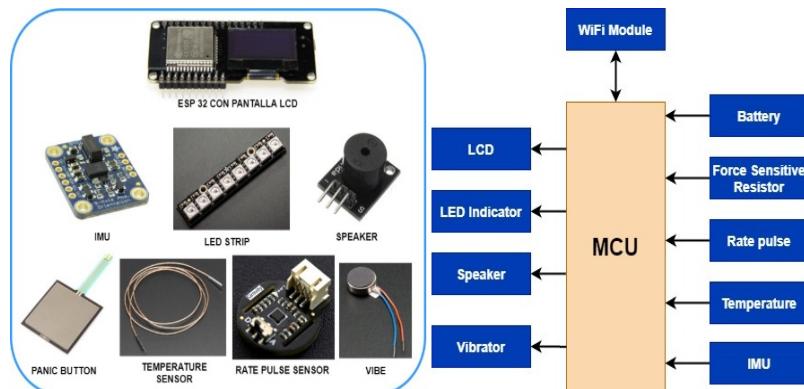


Figure 2. Electronic modules chosen.

It has been decided to use an optical sensor to measure heart frequency, after analyzing the different types of sensors available in this field, such as those based on photoplethysmography techniques, which are much more precise and capable of providing us with important information, for example, the amount of oxygen in the blood. However, this technique performs the analysis on the fingertip and not the wrist, since our proposal is a bracelet, we discarded this option, and an optical sensor has been chosen.

Table 3. Technical specifications of the sensors selected for the device.

Component	Characteristics	Description
Thermocouple Type-K	- Precision: $\pm 1^\circ\text{C}$ - Output range: -6 to 20 mV	Glass braid insulated stainless steel tip which can be used in high temperature.
Heart Rate Monitor Sensor	- Input Voltage (Vin): 3.3–6 V (5 V recommended) - Output Voltage: 0–Vin (Analog) / 0/Vin (Digital) - Operating current: <10 mA	It is based on PPG techniques, to detect blood volume changing in the microvascular bed of tissues
BMI160 Inertial sensor (IMU)	- Sensitivity (typ.) Acc. $\pm 2 \text{ g}$; $\pm 16,384 \text{ LSB/g}$, $\pm 4 \text{ g}$; $\pm 8 \text{ g}$; $\pm 16 \text{ g}$; $\pm 2048 \text{ LSB/g}$ - Sensitivity (typ.) Gyro. $\pm 125^\circ/\text{s}$; $\pm 262.4 \text{ LSB}^{10}/\text{s}$, $\pm 250^\circ/\text{s}$; $\pm 131.2 \text{ LSB}^{10}/\text{s}$, $\pm 500^\circ/\text{s}$; $\pm 65.6 \text{ LSB}^{10}/\text{s}$ - TCS (typ.) (A): $\pm 0.03\%/\text{K}$ (G): $\pm 0.02\%/\text{K}$ - Nonlinearity (typ.) (A): $0.5\% \text{FS}$ (G): $0.1\% \text{FS}$ - Offset (typ.) (A): $\pm 40 \text{ mg}$ (G): $\pm 3^\circ/\text{s}$ - TCO (typ.) (A): $\pm 1.0 \text{ mg/K}$ (G): $0.05^\circ/\text{s/K}$	It is an inertial measurement unit (IMU) consisting of a state-of-art 3 axis, low-g accelerometer, and a low power 3 axis gyroscope.
Square Force-Sensitive Resistor (FSR)	- Actuation Force $\sim 0.2 \text{ N/min}$ - Force Sensitivity Range: $\sim 0.2 \text{ N}$ – 20 N - Force Repeatability Single Part $+/- 2\%$ - Force Repeatability Part to Part $+/- 6\%$ (Single Batch)	FSRs are sensors that allow to detect physical pressure, squeezing, and weight.

The usual optical sensors are made up of photodiodes, i.e., sensors that emit light. They work as follows: We have two light emitters and two light receivers. Once the sensor is activated, the light emits a return reflection that indicates to the bracelet the level of blood in that particular place. Our heart pumps blood causing the reflected light to vary at each instant, this makes it possible to estimate the measurement of the pulses per minute. An example of this type of sensors would be the pulsometer, which can electronically control the heart rate through the electrodes in contact with the skin. Another example is a fiber optic sensor in which the pulses modify the shape of the fiber optic, which in turn causes a variation in the reflection of the light that circulates through it.

Measuring the user's body temperature through an infrared sensor may be slightly imprecise since the device is worn on the wrist and may lose contact with the skin. For this reason, we select a Thermocouple Type-K Glass Braid Insulated Stainless Steel Tip from Adafruit (New York, NY, USA), which are best used for measuring surface temperatures. Because thermocouples are very sensitive, we have included a MAX31855 amplifier from Adafruit (New York, NY, USA), with a cold-compensation reference.

For human activity recognition (HAR), a BMI160 inertial sensor (IMU) from Bosch (Stuttgart, Germany) has been selected for I2C communication without an external magnetometer. The BMI160 is a highly integrated, low power inertial measurement unit (IMU) that provides precise acceleration and angular rate (gyroscopic) measurement. The BMI160 integrates: 16-bit digital, triaxial accelerometer and 16-bit digital, triaxial gyroscope. It is connected to the ESP32 via an I2C port. As a relevant feature, it incorporates two interrupt lines INT1_ACC and INT2_ACC, managed by a specific program that configures them, shown in Figure 3. Through Imu_INT1 the Any-motion, Tap and Step interrupts are detected, and, with Imu_INT2, the Significant-motion, High-G, and No-motion interrupt are detected. At each interruption, the relevant event is posted, thus facilitating the classification of the activity and interpretation of the different types of movement.

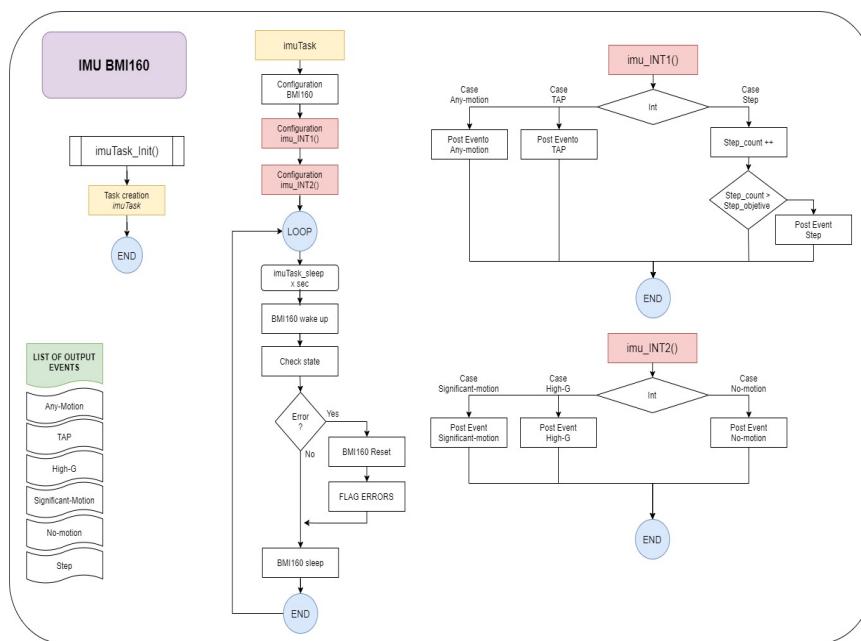


Figure 3. Electronic modules chosen.

The panic button is used by the user to warn of any anomaly or a risk they are experiencing. To do this, we have contemplated the use of piezoresistive sensors that, by means of a certain pressure, can activate an alarm or, on the contrary, can cancel a false alarm.

In addition, it is worthy of mention that the information collected by the bracelet is sent to a control and interactivity interface. The use of adapted control panels and interactive devices in the industrial environment is becoming increasingly common, partly due to the need to manage large volumes of data that are beyond the reasoning capacity of human beings. In this respect, a system has been developed that allows information to be conceptualized and displayed understandably, for rapid and intuitive assimilation. This solution makes it possible to improve users' reaction time and eliminate any doubts that may arise in a critical situation. In the face of a situation that creates stress and uncertainty, it is always more advisable to have a guide that provides simple and effective recommendations.

Figure 4 below shows the board with all the connected sensors and electronic components. Note that the external elements (image on the left) are integrated in the bracelet (image on the right).

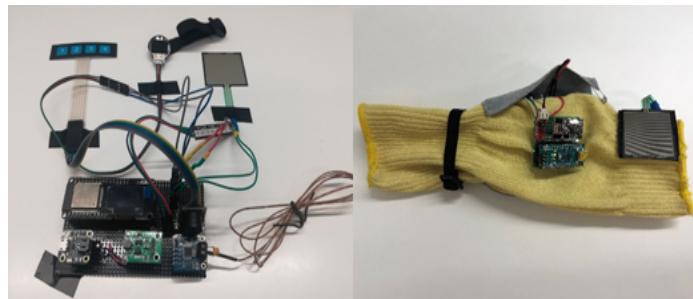


Figure 4. Bracelet with electronic components and their deployment on the fabric.

The bracelet electronics consist in electronic components welded to a flexible proto-board. These are ESP32 with LCD display, Buzzer and monitoring sensor drivers. On the one hand, the electronics responsible for monitoring vital signs and detecting anomalies are attached to the textile part of the bracelet, as shown in the image on the right in Figure 5, including the temperature sensor, pulse sensor and panic button. On the other hand, we have the possibility of visualizing the alarms by means of a LED strip that is also on the outside. The power supply is provided by a 3.7 V Lipo battery, connected to the power module, which charges the bracelet.

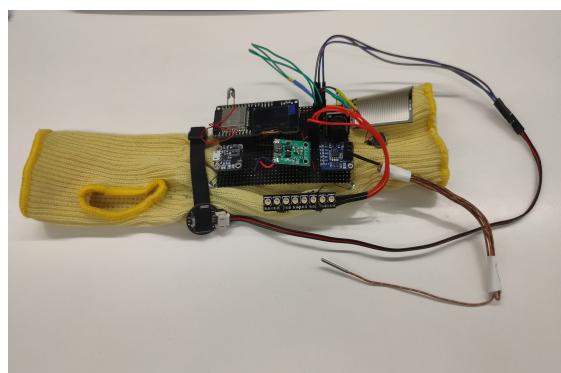


Figure 5. Bracelet with the electronics and sensors included.

The complete system may be made up of multiple modules that take different measurements of the worker's condition and/or their environment. Each bracelet has a communication channel that is used to send the measurements obtained to the concentrator node.

The concentrator node consists of a Raspberry Pi, model 3B, which mounts Ubuntu Mate as its operating system. This node aims to collect the measurements sent by the different devices, store them and route them to a display mechanism. To allow for communication between the measurement devices and the concentrator, the latter provides the system with a Mosquitto server, which implements the MQTT communication protocol. The MQTT protocol has been chosen because it is adapted to the volume of data that needs to be transmitted and also provides native security standards, such as TSL (Transport Layer Security) and SSL (Secure Sockets Layer). The data is sent between the ESP32 microcontrollers and the concentrator in JSON format. In previous work, NVIDIA Jetson Nano has been used, which enables in-hardware processing and edge computing [82].

The data received on the concentrator is collected by software developed in Python 3. This software is responsible for carrying out the storage tasks and sending the data to the display dashboard. For storage, a database implemented in "MongoDB" is used, where the data received by the MQTT protocol are stored. MongoDB has been used because it is a document-oriented database, which provides the possibility of storing the JSON files received without previous transformations. As a dashboard tool, Thingsboard has been chosen, and it provides a versatile and user-friendly data visualization system, as shown in Figure 6. It has a rules engine that allows it to respond to events and record critical situations. The alert system is implemented on this rules engine. The MQTT protocol and the JSON format are again used to send the data between the hub and the Thingsboard servers, both local and remote. In this case, Thingsboard provides its own MQTT server, so it is not necessary to use Mosquitto.

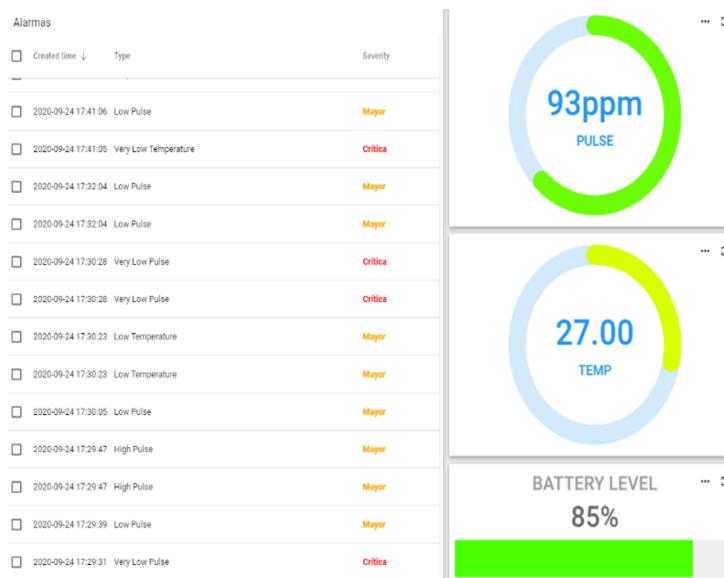


Figure 6. BeSafe B2.0 Platform, bracelet alarm panel.

The data stored in MongoDB is processed by the software developed in Python 3, on a remote machine, more powerful than a Raspberry Pi. The SKLearn library (Scikit-learn) from Python is used to process this data. This library is oriented to processing large blocks of data, including classification algorithms, regression and group analysis. Through

the analysis of these data, it is intended to find behavior patterns that allow to predict anomalous situations. The system architecture is shown in Figure 7 below.

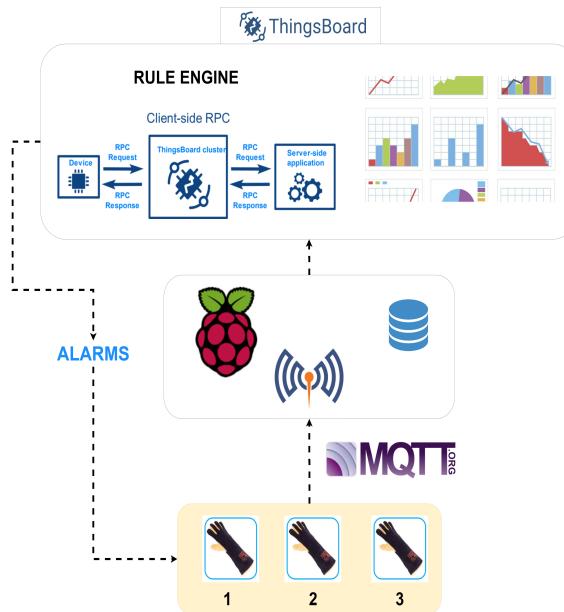


Figure 7. System architecture.

The operation of the bracelet is based on the information it collects from the components: temperature sensor, IMU, cardiac pulse module and the resistive force sensor. It also analyzes the percentage of battery charge. The temperature sensor is used to take body temperature readings, normal body temperature is between 35° and 38°, which is an essential variable when analyzing the worker's medical condition. If the temperature is lower or higher than the established threshold, an alarm is set off to warn the worker, as shown in Figure 8.

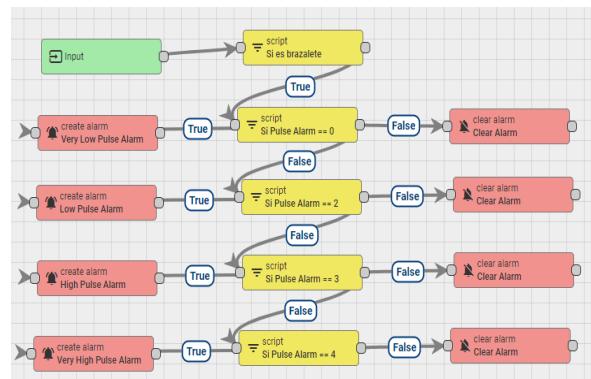


Figure 8. Bracelet pulse alarm configuration.

The cardiac pulse sensor is responsible for analyzing the worker's heartbeat per minute (bpm). The normal heart rate in the human body is between 50 and 110 bpm, if any of the mentioned activation thresholds are exceeded, a notification is issued in order to

take action in response to the situation. The force-resistive sensor is used to activate the panic alarm or to cancel a false alarm. Figure 9 shows the operation of the bracelet and the data on an LCD display.

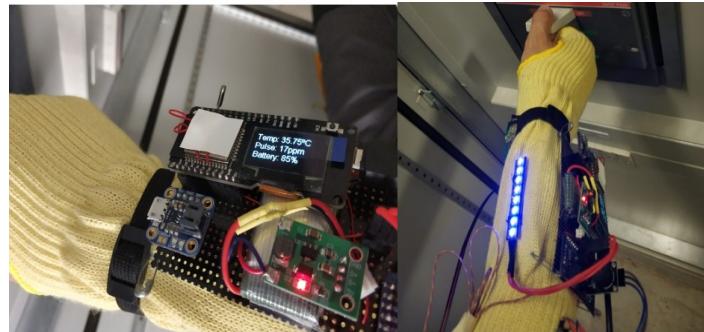


Figure 9. Picture of the data displayed on the screen and of the active pulse alarm.

3.2. Data Analysis and Detection Proposal

The Gaussian Mixture Model is a tool that allows us to group information depending on its characteristics, one of its many advantages is the ability to choose components automatically. This section explains how the information has been analyzed and the different segmentations that have been made of the dataset. The inputs of the model are the user's body temperature, heart rate and a variable indicating the state of the bracelet (the optimal state is determined by the battery and the physical coupling, where the output is the type of distribution to which it belongs). Considering that this is unsupervised learning, depending on the number of components involved, there will be some associated labels. In this study, we used Fisher's analysis to find the populations and on its basis, and the number of components has been defined to be 4. It can be expected that a label among these 4 situations categorized in a real working environment as a heart attack alert through agitation or falls, problems in the user's body temperature, and, in these situations, the virus called COVID-19, is also quite feasible to detect users at risk. Moreover, LSTM is used to analyze the data coming from the IMU of the electronic system. These data are analyzed separately to reduce the noise that can originate from the combination of both and, thus, generate a system with a hybrid analysis, in time series and anomalies; see Figure 10.

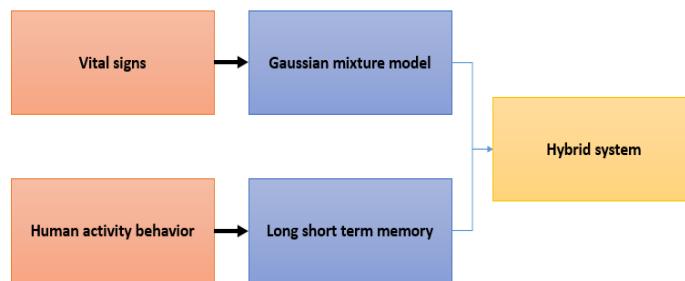


Figure 10. Data analysis through the union of a model based on anomalies and the following one based on time series.

Due to the use of these models in a concise manner, the state of the art has shown that LSTMs work extremely well for time series problems, even if there is no linear correlation, and GMMs have also been used feasibly in alarm systems.

3.2.1. LSTM

As it is well known, there are models proposed specifically for time series analysis; in our case, we make use of one of the most used in the literature for its robustness, the LSTM, a model focused on information recall. This model is based on recurrent neural networks; see Reference [86] to find the details of the theory. In the area of Human Activity Behavior, different situations are studied to try to find a relationship over time with the objective of modeling different circumstances. Our work is focused on the industrial field; therefore, talking to experts in this area, as well as performing a quantitative analysis of the most common activities, they were found to be carrying-sliding objects, walking-standing, and our objective is clearly to analyze shocks.

As it is well known [87], an LSTM is a variant of a Recurrent Neural Network, where the basis is that a sequence can be processed by iterating and maintaining a certain nature containing information in the past. Figure 11 shows the concept behind this. The RNN has the particularity of eliminating or forgetting the information between the processing of two independent sequences, which is why it allows finding patterns on specific time series. Our dataset was taken at a frequency of 50 Hz for 4 consecutive hours from 5 different employees, where the accelerometer data provided by their smartphones was acquired simulating performing the 3 mentioned activities. It is worth mentioning that, since we have an imbalance of data, we performed an oversampling on the falls in order to have a smaller bias.

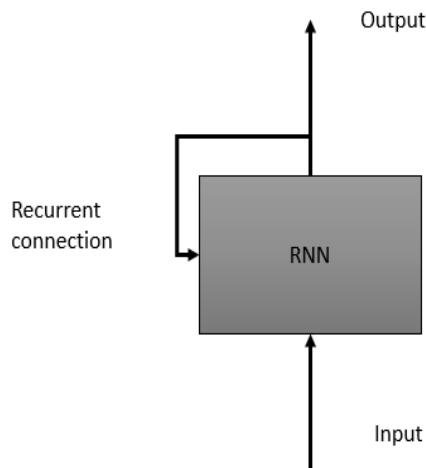


Figure 11. Concept of Recurrent Neural Networks.

One of the ways in which we can generate the hypothesis that our data will be modeled adequately is through finding visual patterns; see Figure 12, where we have displayed the information concerning the drops for the 3 axes, and we can clearly see that there is a similar behavior.

Thus, our objective is to detect possible risks, mainly falls, in order to improve the response time to a dangerous situation. Shocks are not a well sample that can be easily acquired; therefore, several people from the industrial area were asked to simulate this action. Despite the efforts, only a time series of 10,000 sample size was obtained for the

frequency being used (50 Hz as mentioned above). Therefore, data augmentation was used. Data augmentation works through random transformations, depending on the data you want to use, such as images, raw data, or, in this case, time series, and the transformation may vary.

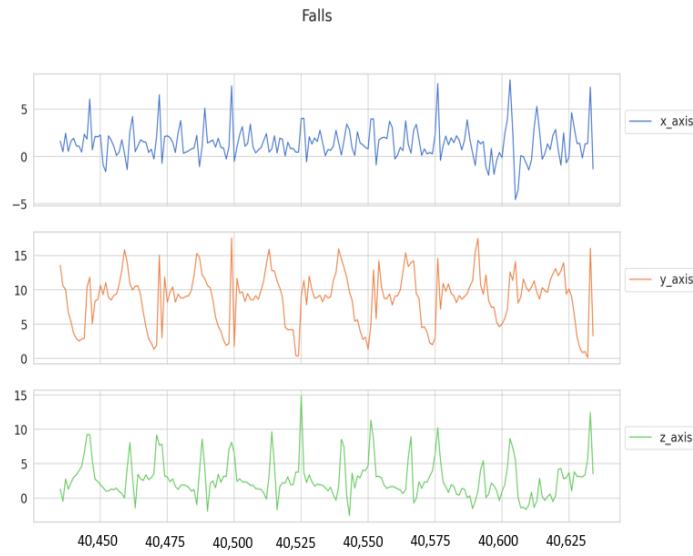


Figure 12. Behavior of the time series for the fall tag.

For the augmentation of the time series data, we rely on the following reference [88]: Suppose we have the time-series $\{A_i\}$, with $1 \leq i \leq n$. And suppose also that we have ϵ that meets the following condition $0 < \epsilon < |A_{i+1} - A_i| \forall i \in \{1, \dots, n\}$.

We can construct a new time series $\{B_i = A_i + r_i\}$, where r_i is a realization of the distribution $N(0, \frac{\epsilon}{2})$.

Then, instead of minimizing the loss function only over $\{A_i\}$, we do that also over $\{B_i\}$. So, if the optimization process takes m steps, we have to initialize the predictor $2m$ times, and we will compute approximately $2m(n - 1)$ predictor internal states. Thanks to the increase in time series data, we went from 10,000 samples for the fall class to more than 70,000 samples for the fall class.

The dataset was composed as in the following, Figure 13, and it should be considered that the dataset for the different actions obtained constituted an unbalanced set, to which can be added the different performance shown below in the confusion matrix. The first two activities carrying-displaying and Walking Standing were acquired during normal performance. However, for the Falls class, the simulation had to be performed by different workers on different surfaces, as can be seen, and it was the class with the smallest number of data.

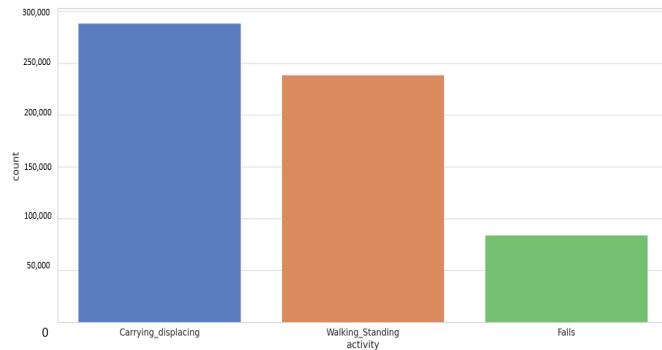


Figure 13. Histogram diagram of number of samples by class.

Now that we know the input for our model we proceed to train the LSTM, of which we have the following characteristics: we have 200 time steps, with a training set dimension $\in \mathbb{R}^3 (12,670, 200, 3)$, it is a sequential model, where we have 128 units for the LSTM, our learning rate 0.5, a hidden layer with activation function relu and of course output layer with softmax it is already a multiclass classification problem. We train it with 100 epochs where, as shown in Figure 14, you can see the history of the loss in the training and testing set.

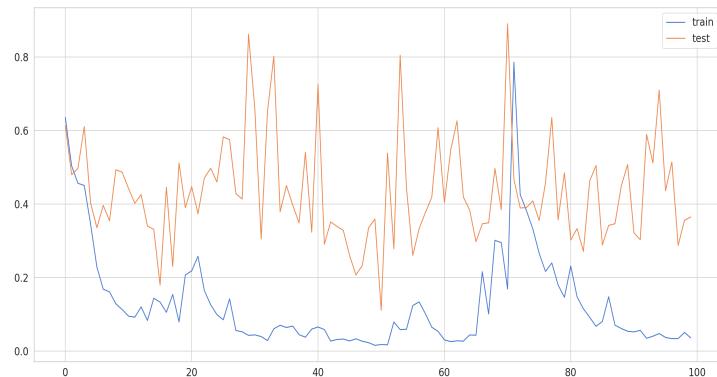


Figure 14. LSTM history loss training and testing dataset.

To come to the result of the confusion matrix, a combination of hyperparameters was performed where the number of units was varied between 64 and 128 for the LSTM, as well as the learning step between 0 and 0.5, with steps of 0.05 and number of epochs between 10 and 100, where, as in Figure 15, it is equivalent to the output given the configuration described above. We will now proceed to explain the anomalies part.

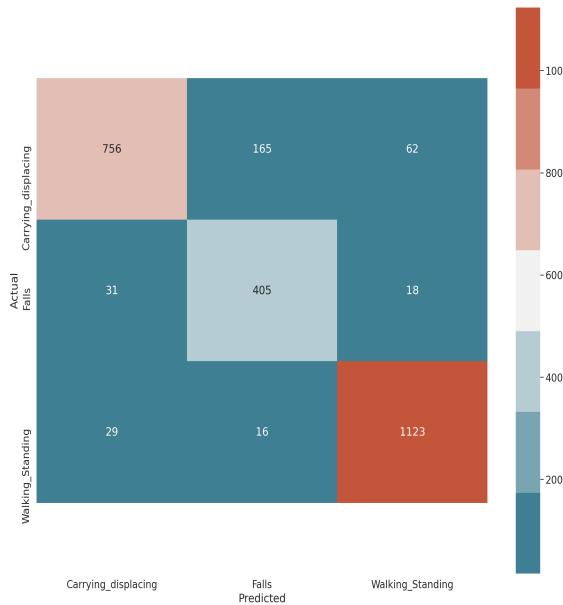


Figure 15. Confusion matrix LSTM.

3.2.2. GMM

On the basis of the state of the art and the model proposed to solve the problem, the mathematical basis of the GMM. As mentioned, the GMM is a parametric probability density function represented as a Gaussian weighted sum of the component densities. In GMM, parameters are estimated from training data using the iterative Expectation-Maximization (EM) algorithm or the Maximum A Posteriori Estimation (MAP).

Unlike *K-Means*, this method's purpose is to fit Gaussian M to the data. After this step, the Gaussian distribution parameters, such as mean and variance for each cluster and the weight of a cluster, are found. Finally, for each data point, the probabilities of belonging to each of the clusters are calculated. A model based on a Gaussian distribution can be written as seen in Equation (1) [89].

$$p(x|\lambda) = \sum_{i=1}^M w_i g(x|\mu_i, \sigma_i), \quad (1)$$

where Equation (1) establishes a univariate case; in other words, it is a one-dimensional model. The definition continues in Equation (2).

$$g(x|\mu_i, \sigma_i) = \frac{1}{\sigma_i \sqrt{2\pi}} \exp\left(-\frac{(x - \mu_i)^2}{2\sigma_i^2}\right), \quad (2)$$

where, for both Equations (1) and (2), μM = mean and σM = variance for each of the M -th element, x is a D -dimensional continuous-valued data vector (i.e., measurement or features), and $w_i, i = 1, \dots, M$ are the mixture weights.

When the case being addressed has multivariate problems Equation (3) is applied.

$$p(\vec{x}) = \sum_{i=1}^M w_i g(\vec{x}|\vec{\mu}_i, \sum_i), \quad (3)$$

where μ_M = mean and Σ_M covariance matrix (provides the covariance between each pair of elements of a random vector in the form of a square matrix) for the M -th element. In addition, wk = weight for cluster M [69]. The algorithm is trained on these M clusters. Thus, given a new data point, the algorithm finds its distance from each distribution and, therefore, the probability that that point belongs to each cluster. Therefore, if the probability is minimal for a particular cluster, *that is an indication that the data point is an anomaly*.

The GMM is parameterized by means of the mean vectors, the covariance matrices, and the blend weights of all component densities. These parameters are represented collectively by Equation (4) [90].

$$\lambda = \left\{ w_i, \mu_i, \Sigma_i \right\}, \quad (4)$$

where $i = 1, \dots, M$. It is also possible to use the linear combination of the Gaussian diagonal covariance base to model the correlations between the vector elements of the features. The effect of using a full Gaussian covariance matrix M set can also be obtained by using a larger set of diagonal Gaussian covariance.

Now, the *Maximum Likelihood (ML) Parameter Estimation*, used to estimate the parameters of the GMM, is described. In a sequence of T training vectors $X = \{x_1, \dots, x_T\}$, the GMM likelihood can be written as Equation (5).

$$p(X|\lambda) = \prod_{t=1}^T p(x_t|\lambda). \quad (5)$$

Given the first model λ , the aim of this method is, to calculate another model λ' , based on $p(X|\lambda') \geq p(X|\lambda)$. Given the above, to estimate the MAP Parameter Estimation is used to calculate GMM parameters via the EM algorithm, which is identical to the *Expectation step of the EM algorithm*. After that, it is combined with a sufficient amount of *old* statistics of the above mixing parameters using a data dependent mixing ratio. Now that the GMM has been described, we move onto describing the electronic design, as well as the implementation of the model in the generated data.

Subsequently, data processing and its modeling are described.

4. Data Pre-Processing

A sample of 40,000 points of data was obtained with a frequency of 6 points of data per minute, where each of the components of the bracelet gave the corresponding information through wireless communication. Depending on the values of body temperature, heart rate, and battery of the system, labels were created to simulate the actions or events in different situations, mainly for industrial or transport areas; 4 different classes were generated by the mentioned situations, which are:

- Worker with stable vital signs and non-hostile environment, which we will define as SVSNHE.
- Worker with smooth variation in vital signs, SVVS.
- Worker with vital signs in danger and non-hostile environment, defined here as SVDNHE.
- Worker in danger due to hostile environment, DHE.

For the dataset acquired, the information was taken from workers in the industrial area where the total number of subjects was 7 persons all male with an average age of 34 years and average weight of 72 kg. Each subject was monitored over the course of 15 working days, collecting the aforementioned data, and each user had to fill out a questionnaire at the end of each day to find out how they felt physically, not forgetting any injuries that may have occurred during that week. Since the atypical data were not recurrent during this time, 2 of the 7 workers were asked to simulate falls and situations where their heart rate

was abnormal. The environment in which the simulations were carried out was a company in charge of the construction of platforms and infrastructure.

Then, an ANOVA-Fisher analysis was performed, which allowed us to identify that there is a significant variation over the data populations, and, as it can be seen in Table 4, there is no class that shares similar characteristics with another; therefore, it is possible to create clusters over the data.

Table 4. Fisher analysis performed to determine the components to be used.

Grouping Information Using the Fisher LSD Method and 95% Confidence			
Temp	N	Mean	Grouping
36.50	168	5.000	A
42.00	303	4.0264	B
41.75	761	4.01840	B
40.50	1051	4.01808	B
40.25	809	4.01731	B
41.00	2183	4.01466	B
40.75	1601	4.01437	B
41.25	1520	4.01118	B
41.50	1131	4.00973	B
40.00	301	4.0033	B
42.25	166	3.99398	B
39.50	1	2.0000	C
39.00	1	2.0000	C
38.50	1	2.0000	C
38.25	1	2.0000	C
37.50	1	0.0000	D
37.50	1	0.0000	D

Given that there is a significant variation in classes, it is necessary to employ methodologies that cluster data and classify actions or environments. Among these methodologies are unsupervised algorithms with classical or fuzzy techniques, such as FCM. In the present work, we focus on grouping by comparing the K-Means method and the GMM.

5. Detecting Anomalies with an Electronic Bracelet

In order to explore how the bracelet data allows us to find information that may be relevant in different environments, be it work, transportation, health, we modeled the samples with 1 grouping methods. The K-Means looks for similarities and allows us to group them. See Figure 16, although 4 characteristics have been established through Fisher's analysis, the dispersion of the data without restriction is shown. At first sight, we can already see the way in which information is dispersed.

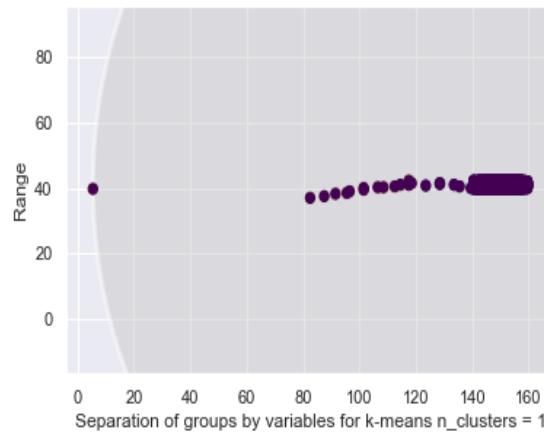


Figure 16. The K-Means between temperature and heartbeat, without constrain.

In Figure 17, we place a circle over each of the clusters to delimit the samples for 2 variables that belong to each label. Considering the fact that it is unsupervised learning, it is possible to identify the points that, in spite of their belonging to a specific group, are not grouped where most data are. This makes the problem binary and facilitates the application of a probabilistic approach. Imagine a situation where we only want to determine whether workers in a mine are within an *acceptable* range or are at risk.

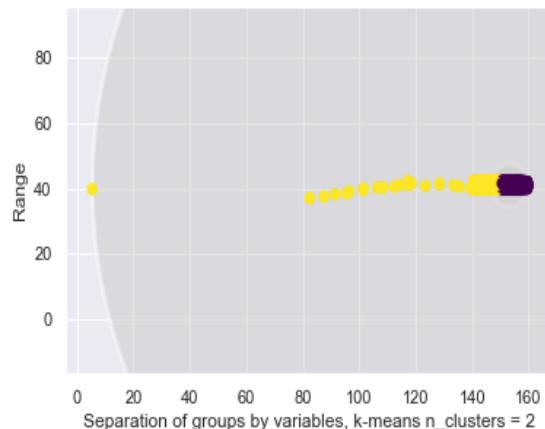


Figure 17. The K-Means between temperature and heartbeat with 2 clusters.

This study shows us that K-Means encounters difficulties when modeling the data and tries to separate them independently, shown previously in Figures 17 and 18 below, as the circles defined by the algorithm overlap. This is because K-Means tries to group the data within the defined radius. However, there should be enough flexibility to find the groupings that do not interfere with others. For example, the yellow samples completely cover the other 3 clusters, although it is shown that each one is defined by a smaller radius, which is the term of the next cluster.

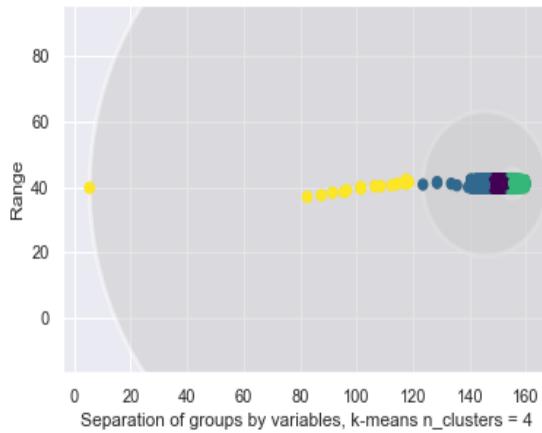


Figure 18. Delimited groupings for 4 labels and 2 variables.

Regarding the following model, the GMM allows us to find the data that fits a distribution. This is an advantage to the bracelet since it enables it to identify the data that are in a range of normality against to those that are not. Abnormal behaviors are identified by the proposed system as possible risks in the user's environment. Specifically, as seen above, k-means operates in a non-probabilistic manner. It uses simple distance from the center of the cluster to assign membership, which results in poor performance in many real world situations. See Figure 19, where the two biggest data clusters, green and yellow, and the distribution of samples are all grouped in a range of 40 to 42 and 140–160 for the ordinate axis.

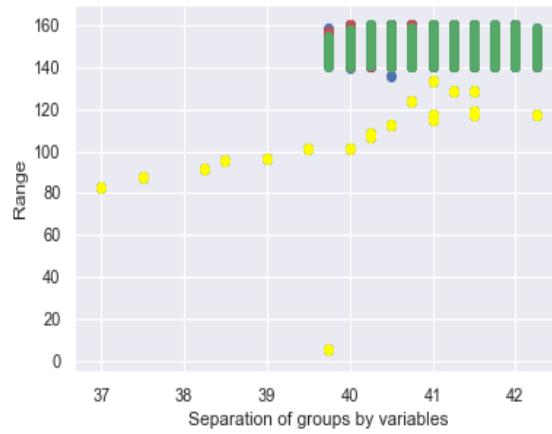


Figure 19. GMM distribution of the 2 classes on the bracelet.

The way of working of the GMM is to find sets in multidimensional data, often called mixtures, to identify the data that are considered normal in a dataset, as shown in Figure 20, where the 4 classes are plotted with respect to the GMM and its groupings. It is possible to see the dispersion of the clusters and the overlap between them.

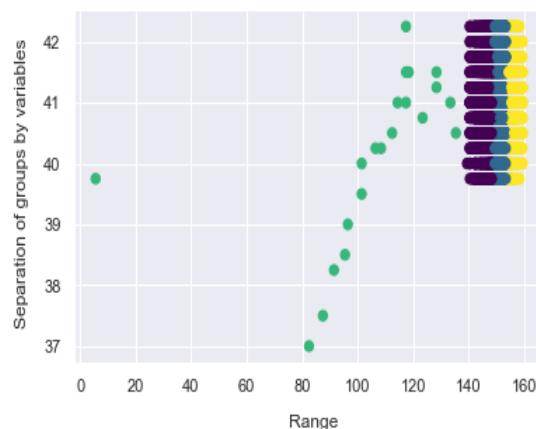


Figure 20. GMM distribution of the 4 classes on the bracelet.

As shown in Figure 20, it is possible to establish the sample size in proportion to its prediction, where the farthest sample represents the end of the clustering as was the case with K-Means. The GMM uses expectation maximization that chooses initial assumptions for location and shape. As with the K-Means expectation optimization approach, this algorithm can sometimes overlook the overall optimal solution, so it is used multiple random initialization.

Figure 21 shows the result; each cluster is associated with a smooth Gaussian model, and not with a hard edge sphere. As in the K-Means expectation optimization approach, this algorithm can sometimes overlook the overall optimal solution, so multiple random initialization is used.

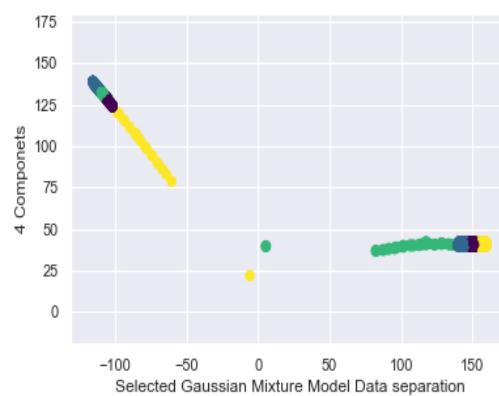


Figure 21. Data separation by GMM.

When an anomaly is detected, the information is transmitted via Internet to indicate that there is a possible risk due to the worker's pulse or temperature. These two clinical variables are extremely important, and they are indispensable in the current situation caused by COVID-19, where an anomalous biological behavior can be detected in order to take action on the matter.

For the training of the system, it is useful to know that we had an unbalanced dataset, where the 80–20 ratio was used for testing and training. Subsequently, real-time tests

were performed, where the results are also included. See Figure 22, where we include the comparison of K-Means versus GMM, as it is well known that we can have a better approximation through the GMM.

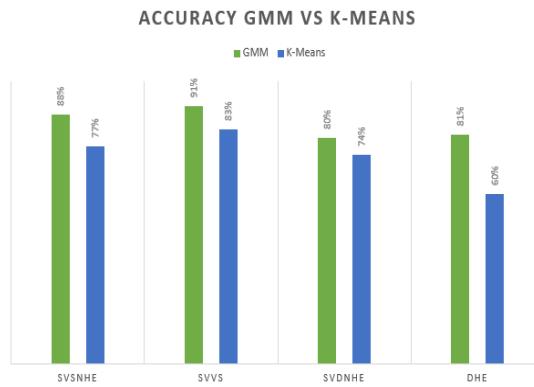


Figure 22. Comparation GMM versus K-Means.

However, when we performed the real-time test, we had a decrease in the percentage of accuracy, as shown in Figure 23, and the test was performed over 3 days on 4 different subjects from the same company. A solution for this decrease in percentage may well be to increase the number of subjects from which data was extracted or to increase the sampling time. The decrease in the percentage may be due to other factors, one of them the overlapping of data from one class to another; therefore, one of the proposals for the future is spectral clustering by decomposing the data in its eigenvector representation to maximize the effectiveness of this process. The relevance of our work is in merging emerging technologies that are becoming indispensable in smart cities for smart work with smart health services.

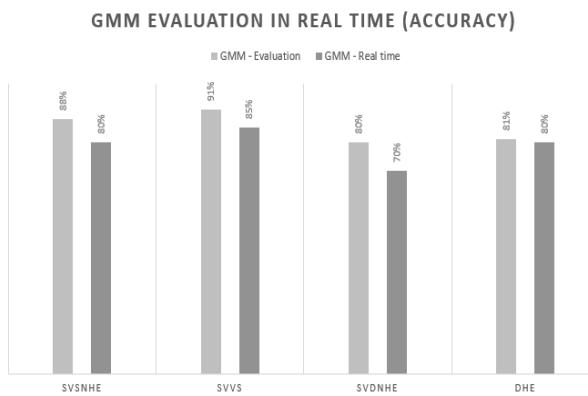


Figure 23. Results of GMM in real time.

In addition, included in Figures 24 and 25 is the ROC curve for the two models used specifically for vital signs and the state of the environment, and it can be seen that GMM works better on the number of negative alarms; this comparison helps us to quantitatively see the best option for sending information to the platform.

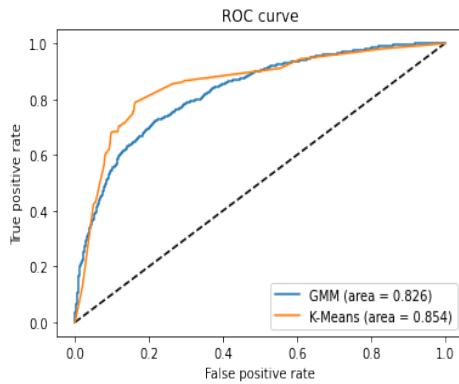


Figure 24. ROC curve for GMM and K-Means, showing the rate of false alarms versus true alarms.

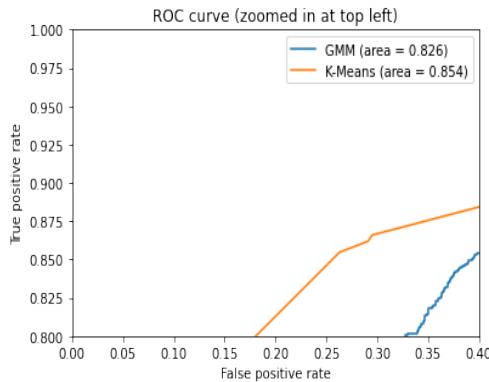


Figure 25. ROC curve for GMM and K-Means, zoomed in at top left.

To send the information to the platform is done in a simple way: a class was made which through the transmission protocol Lab Streaming Layer, where each model receives in real time the inputs with which each model works; once this is known to be mapped from $f(x)$, our hypothesis, or modeled to \mathbb{R} , then, again, to the Lab Streaming Layer, the real value is sent along with an identified, which is 0 for GMM and 1 for LSTM. This, in turn, enters the platform that was presented in Figures 6 and 8.

6. Conclusions and Discussion

The improvements presented in this work involved the incorporation of new materials and functions in the previously developed protective equipment and an improved centralized platform, offering assistance and visualization services. In conjunction with the bracelet, the platform is highly valuable for risk prevention and medical-health anticipation. The AIoT technological innovations introduced by the bracelet make it possible to monitor aspects that affect the workers' health. It provides information on the physical parameters and human activity recognition and also analyzes the environment using the capacity provided by Smart Data to detect situations that could lead to occupational illness.

In comparison to state-of-the-art literature, we find that models trained on data from an industrial environment are indeed challenging. In 2016, Reference [56] presented a paper for human activity detection where the authors obtained 92.1% accuracy with a public dataset; however, in our best class classification, we obtained 92% in non-daily tasks, and our activities included moving objects around, carrying and manipulating tools,

etc. Therefore, similar accuracy is synonymous with good information acquisition and processing system.

Likewise, an excellent work focused on time series problems, specifically with LSTM and wearable products, was presented in Reference [57], where the authors proposed a framework that was validated across two datasets and convolutional network architectures (specifically, 4 convolutional layers), and its performance was 0.958. In our case, joining all the data on the LSTM gave us a performance that did not exceed 0.70, which is why it was decided to divide the approach of the work into two models; a future work is to implement not a parallel model but to join the advantages of GMM and LSTM in one.

It can also be said that works similar to ours have tried to use different types of regularizations for the deep models [91], where the influence of such improvements was shown. Comparing our work with this one, we can say that our approach is more on the side of using later optimization through Auto Machine Learning, where Gaussian processes and Bayesian optimization will be used to identify the optimal hyperparameter space in the model.

After considering all of the above, it can be concluded that it is extremely important to continue increasing the robustness of devices through information and communication technologies, as well as artificial and electronic intelligence. These technologies enable devices to identify when there is an anomaly in the data obtained by different sensors. Moreover, to transmit the information for decision-making, the present work proposes the detection of anomalies through a multisensorial intelligent bracelet. This bracelet will be implemented in a real environment at a later stage.

The results presented in this paper show that deep learning-based approaches for activity recognition, in the GMM, regularly have associations of the data in each group, and we can also identify the separation of the samples that fall in a range of normality, as in the K-Means optimization approach. Unlike K-Means, the clusters are not identified by a defined diameter, instead, the groups is adapted to a distribution, which makes it is possible to reduce the number of false positives and to identify real risk situations for bracelet wearers. The GMM allows us to identify data that indicate a hazard, even if the groups overlap, this is because it identifies the patterns that define each of the labels.

In the present work, four labels were used to represent different situations. The GMM allowed us to separate them and label those that do not fall within a normal distribution in a multivariate manner. The anomalies are reported to the competent authority by sending the information over the internet. This proposal is applicable to different industries, such as health, where the platform indicates unidentified traits. Moreover, thanks to its heart rate sensor, it can be used by workers in the construction area in order to avoid possible accidents caused by cardiac arrest or fainting due to high body temperatures.

In addition, the research proposes the inclusion of more sensors that work together, as well as a panic button. The system's adaptive learning enables it to categorize data independently through real-time monitoring. Unlike other state-of-the-art proposals in the literature and already registered patents, we do not establish the classification of labels, we focus on finding critical values in the samples to increase the percentage of true positives and false positives. Part of the future work also involves further exploring the robustness of the proposal with larger datasets.

The BeSafe 2.0 platform and the AIoT bracelet offer a variety of services that meet the needs of different target audiences. Thus, it is necessary to develop a dissemination and communication plan that would be capable of transmitting the generated knowledge and results for their fair and effective use. The dissemination and communication plan must stress the high benefits offered by the proposal, with a high Return on Investment (ROI), given the reduced number of sick leaves and accidents associated with Occupational Risk Prevention (ORP). The market for this type of solutions has been growing in the recent years, showing encouraging results, with an expected growth rate of 15.43% for the period 2017–2021. Moreover, it is expected that, in 2022, this sector will reach a 6% growth, amounting to more than 58 B\$.

Future lines of research will focus on identifying variations in audio signals through a microphone and on the use of algorithms, such as LSTM, to identify anomalies in the data or triggers to send information to the point concerned. We will also propose to use the bracelet in the mobility and logistics sectors, where it could indicate irregularities in traffic anomalies, minimize accidents and even reduce the time taken to transport goods. All these applications would be on the benefit of the economic sectors employing the solution; therefore, they will be explored in a future research.

Finally, it is necessary to continue developing new proposals and protective equipment for different areas of application, adapting the technology to meet their security needs. Among these areas, we are especially interested in providing solutions to people with dementia or patients of some type of neurological disease, such as Alzheimer's. Thanks to the device, we could prevent people from getting lost or disoriented. Another field that could be covered is the application of the device by people who have suffered some kind of abuse or harassment, as the remote monitoring of the patients' health would be needed.

Author Contributions: Conceptualization and methodology S.M.-S.; Data Curation I.C.-J.; and D.R.-C.; writing—original draft preparation S.M.-S. and I.C.-J.; data curation I.C.-J.; validation S.R.; and J.M.C.-R.; writing, review and editing S.R.; and S.M.-S.; All authors have read and agreed to published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Acknowledgments: This research was partially Supported by the project “Computación cuántica, virtualización de red, edge computing y registro distribuido para la inteligencia artificial del futuro”, Reference: CCTT3/20/SA/0001, financed by Institute for Business Competitiveness of Castilla y León, and the European Regional Development Fund (FEDER).

Conflicts of Interest: The authors declare no conflict of interest.

Sample Availability: Samples of the compounds are available from the authors.

References

- Podgorski, D.; Majchrzyc, K.; Dąbrowska, A.; Gralewicz, G.; Okrasa, M. Towards a conceptual frame-work of OSH risk management in smart working environments based on smart PPE, ambient intelligence and the Internet of Things technologies. *Int. J. Occup. Saf. Ergon.* **2017**, *23*, 1–20. [[CrossRef](#)]
- Bensel, C.K.; Santee, W.R. Use of Personal Protective Equipment in the Workplace. In *Handbook of Human Factors and Ergonomics*; John Wiley & Sons, Inc.: Hoboken, NJ, USA, 2006; pp. 912–928.
- Campero-Jurado, I.; Márquez-Sánchez, S.; Quintanar-Gómez, J.; Rodríguez, S.; Corchado, J.M. Smart Hel-met 5.0 for industrial internet of things using artificial intelligence. *Sensors* **2020**, *20*, 6241. [[CrossRef](#)]
- Ruiz Pérez, G. Accidentes de Trabajo Mortales en España: Una Visión Histórica-Estructural. Bachelor’s Thesis, Universidad Autónoma de Madrid, Madrid, Spain, 2019.
- Sánchez, S.M.; Vara, R.C.; Criado, F.J.G.; González, S.R.; Tejedor, J.P.; Corchado, J.M. Smart PPE and CPE Platform for Electric Industry Workforce. In Proceedings of the 14th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2019), Seville, Spain, 13–15 May 2019; Springer: Cham, Switzerland, 2019.
- Márquez Sánchez, S. Electronic Textiles for Intelligent Prevention of Occupational Hazards. In Proceedings of the International Symposium on Distributed Computing and Artificial Intelligence, L’Aquila, Italy, 17–19 June 2019; Springer: Cham, Switzerland, 2019.
- Pavón, I.; Sigcha, L.; López, J.; De Arcas, G. Wearable technology usefulness for occupational risk prevention: Smartwatches for hand-arm vibration exposure assessment. In Proceedings of the Occupational Safety and Hygiene V: Selected Papers from the International Symposium on Occupational Safety and Hygiene, Guimarães, Portugal, 10–11 April 2017; CRC Press: Boca Raton, FL, USA, 2017; pp. 77–82.
- Bokor, Z. Integrating logistics cost calculation into production costing. *Acta Polytech. Hung.* **2012**, *9*, 163–181.
- Dong, X.L.; Srivastava, D. Big data integration. In Proceedings of the 2013 IEEE 29th International Conference on Data Engineering (ICDE), Brisbane, Australia, 8–12 April 2013.

10. Lenzerini, M. Data integration: A theoretical perspective. In Proceedings of the Twenty-First ACM SIGMOD-SIGACT-SIGART Symposium on Principles of Database Systems, Madison, WI, USA, 3–5 June 2002.
11. Clifton, C.; Kantarcioğlu, M.; Doan, A.; Schadow, G.; Vaidya, J.; Elmagarmid, A.; Suciu, D. Priva-cy-preserving data integration and sharing. In Proceedings of the 9th ACM SIGMOD Workshop on Re-search Issues in Data Mining and Knowledge Discovery, Paris, France, 13 June 2004.
12. Rodríguez, S.; De Paz, J.F.; Villarrubia, G.; Zato, C.; Bajo, J.; Corchado, J.M. Multi-agent information fu-sion system to manage data from a WSN in a residential home. *Inf. Fusion* **2015**, *23*, 43–57. [[CrossRef](#)]
13. Bajo, J.; De Paz, J.F.; Villarrubia, G.; Corchado, J.M. Self-organizing architecture for information fusion in distributed sensor networks. *Int. J. Distrib. Sens. Netw.* **2015**, *11*, 231073. [[CrossRef](#)]
14. Incel, O.D.; Kose, M.; Ersoy, C. A review and taxonomy of activity recognition on mobile phones. *BioNanoScience* **2013**, *3*, 145–171. [[CrossRef](#)]
15. Kwapisz, J.R.; Weiss, G.M.; Moore, S.A. Activity recognition using cell phone accelerometers. *ACM SigKDD Explor. Newsl.* **2011**, *12*, 74–82. [[CrossRef](#)]
16. Fahim, M.; Fatima, I.; Lee, S.; Park, Y.T. EFM: Evolutionary fuzzy model for dynamic activities recognition using a smartphone accelerometer. *Appl. Intell.* **2013**, *39*, 475–488. [[CrossRef](#)]
17. Lara, O.D.; Labrador, M.A. A mobile platform for real-time human activity recognition. In Proceedings of the 2012 IEEE Consumer Communications and Networking Conference (CCNC), Las Vegas, NV, USA, 14–17 January 2012.
18. Rachuri, K.K.; Musolesi, M.; Mascolo, C.; Rentfrow, P.J.; Longworth, C.; Aucinas, A. EmotionSense: A mobile phones based adaptive platform for experimental social psychology research. In Proceedings of the 12th ACM International Conference on Ubiquitous Computing, Copenhagen, Denmark, 26–29 September 2010.
19. Consolvo, S.; McDonald, D.W.; Toscos, T.; Chen, M.Y.; Froehlich, J.; Harrison, B.; Klasnja, P.; LaMarca, A.; LeGrand, L.; Libby, R.; et al. Activity sensing in the wild: A field trial of ubifit garden. In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, Florence, Italy, 5–10 April 2008.
20. Rodriguez, S.; Corchado, J.M. Smart Belt Design by Naïve Bayes Classifier for Standard Industrial Protection Equipment Integration. *Int. J. Artif. Intell.* **2020**, *18*, 186–201.
21. Chamoso, P.; De Paz, J.F.; Bajo, J.; Villarrubia, G. Intelligent control of energy distribution networks. In Proceedings of the International Conference on Practical Applications of Agents and MultiAgent Systems, Seville, Spain, 1–3 June 2016.
22. Puig Ramírez, J. Asset optimization and predictive maintenance in discrete manufacturing industry. *IFAC Proc. Vol.* **2012**, *45*, 1–6.
23. Porter, M.E.; Heppelmann, J.E. How smart, connected products are transforming companies. *Harv. Bus. Rev.* **2015**, *93*, 96–114.
24. Chimeno, S.G.; Fernández, J.D.; Sánchez, S.M.; Ramón, P.P.; Ospina, Ó.M.S.; Muñoz, M.V.; Hernández, A.G. Domestic Violence Prevention System. In Proceedings of the International Symposium on Distrib-uted Computing and Artificial Intelligence, Toledo, Spain, 20–22 June 2018.
25. Yao, B.; Zhou, Z.; Xu, W.; Fang, Y.; Shao, L.; Wang, Q.; Liu, A. Service-oriented predictive maintenance for large scale machines based on perception big data. In Proceedings of the ASME 2015 International Manufacturing Science and Engineering Conference, Charlotte, NC, USA, 8–12 June 2015.
26. Heras, S.; De la Prieta, F.; Julian, V.; Rodríguez, S.; Botti, V.; Bajo, J.; Corchado, J.M. Agreement technolo-gies and their use in cloud computing environments. *Prog. Artif. Intell.* **2012**, *1*, 277–290. [[CrossRef](#)]
27. De la Prieta, F.; Gil, A.B.; Rodríguez-González, S.; Corchado, J.M. Cloud Computing and Multi Agent System to improve Learning Object Paradigm. *JxD&A* **2014**, *23*, 38–49.
28. Shi, W.; Dustdar, S. The promise of edge computing. *Computer* **2016**, *49*, 78–81. [[CrossRef](#)]
29. Maria, A.R.; Sever, P.; George, S. MIoT applications for wearable technologies used for health monitoring. In Proceedings of the 2018 10th International Conference on Electronics, Computers and Artificial Intel-ligence (ECAI), Iasi, Romania, 28–30 June 2018.
30. Dupuis, H.; Zerlett, G. Whole-body vibration and disorders of the spine. *Int. Arch. Occup. Environ. Health* **1987**, *59*, 323–336. [[CrossRef](#)]
31. Gardner, R.O.N. Overview and characteristics of some occupational exposures and health risks on offshore oil and gas installations. *Ann. Occup. Hyg.* **2003**, *47*, 201–210.
32. Celli, C.H.; Duffy, G.W.; McGuckin, J.P. Methods and Systems for the Industrial Internet of Things. U.S. Patent No. 10,394,210, 27 August 2019.
33. Dhull, R.; Chava, D.; Kumar, D.V.; Prasad, K.M.; Samudrala, G.; Bhargav, M.V. Pandemic Stabilizer using Smartwatch. In Proceedings of the 2020 International Conference on Decision Aid Sciences and Applica-tion (DASA), Online, 8–9 November 2020.
34. Adjiski, V.; Despodov, Z.; Mirakovski, D.; Serafimovski, D. System architecture to bring smart personal protective equipment wearables and sensors to transform safety at work in the underground mining industry. *Rudarsko-Geološko-Naftni Zbornik* **2019**, *34*, 37–44. [[CrossRef](#)]
35. Frederick, W.H.; Miller, C.M. Monitoring Bracelet. U.S. Patent Application No. 29/234,869, 16 January 2017.
36. Connor, R.A. Wearable Device for the Arm with Close-Fitting Biometric Sensors. U.S. Patent No. 10,627,861, 21 April 2020.
37. Magno, M.; Brunelli, D.; Sigrist, L.; Andri, R.; Cavigelli, L.; Gomez, A.; Benini, L. InfiniTime: Multi-sensor wearable bracelet with human body harvesting. *Sustain. Comput. Inform. Syst.* **2016**, *11*, 38–49. [[CrossRef](#)]

38. Ouwerkerk, M.; Dandine, P.; Bolio, D.; Kocielnik, R.; Mercurio, J.; Huijen, H.; Westerink, J. Wireless multi sensor bracelet with discreet feedback. In Proceedings of the 4th Conference on Wireless Health, Baltimore, MD, USA, 1–3 November 2013.
39. Fortino, G.; Galzarano, S.; Gravina, R.; Li, W. A framework for collaborative computing and multi-sensor data fusion in body sensor networks. *Inf. Fusion* **2015**, *22*, 50–70. [[CrossRef](#)]
40. Singh, E.M.; Meyyappan, Nalwa, H.S. Flexible graphene-based wearable gas and chemical sensors. *ACS Appl. Mater. Interfaces* **2017**, *9*, 34544–34586. [[CrossRef](#)] [[PubMed](#)]
41. Trung, T.Q.; Ramasundaram, S.; Hwang, B.U.; Lee, N.E. An all-elastomeric transparent and stretchable temperature sensor for body-attachable wearable electronics. *Adv. Mater.* **2016**, *28*, 502–509. [[CrossRef](#)]
42. Parara, A.; Sekka, S. Wearable Care Security Smart Watch Device. U.S. Patent Application No. 15/162,121, 23 May 2016.
43. Gope, C. Use of a Smart Watch for seizure/abnormal motion activity monitoring and tracking. *Epilepsy Behav.* **2015**, *46*, 52–53. [[CrossRef](#)]
44. Nguyen, D.N. Smart Watch with Automatic Voice Recording and Alarm. U.S. Patent No. 9,805,576, 31 October 2017.
45. Chen, M.; Zhang, Y.; Qiu, M.; Guizani, N.; Hao, Y. SPHA: Smart personal health advisor based on deep analytics. *IEEE Commun. Mag.* **2018**, *56*, 164–169. [[CrossRef](#)]
46. Shin, D.; Shin, D.; Shin, D. Ubiquitous health management system with watch-type monitoring device for dementia patients. *J. Appl. Math.* **2014**, *2014*, 878741. [[CrossRef](#)]
47. Shin, D.-M.; Shin, D.; Shin, D. Smart watch and monitoring system for dementia patients. In Proceedings of the International Conference on Grid and Pervasive Computing, Daegu, Korea, 9–11 May 2013.
48. Alsulami, M.H.; Atkins, A.S.; Campion, R.J. The use of smart watches to monitor heart rates in elderly people: A complementary approach. In Proceedings of the 2016 IEEE/ACS 13th International Conference of Computer Systems and Applications (AICCSA), Agadir, Morocco, 29 November–2 December 2016.
49. Perez, M.N.; Mata, F.J.A.; Rodriguez, V.M.Z.; Zhang, S. Pervasive healthcare monitoring system. In Proceedings of the 2015 IEEE 12th International Conference on Ubiquitous Intelligence and Computing and 2015 IEEE 12th Intl Conf on Autonomic and Trusted Computing and 2015 IEEE 15th International Conference on Scalable Computing and Communications and Its Associated Workshops (UIC-ATC-ScalCom), Beijing, China, 10–14 August 2015.
50. Reeder, B.; David, A. Health at hand: A systematic review of smart watch uses for health and wellness. *J. Biomed. Inform.* **2016**, *63*, 269–276. [[CrossRef](#)]
51. Manisha, M.; Neeraja, K.; Sindhura, V.; Ramaya, P. IoT on heart attack detection and heart rate monitoring. *Int. J. Innov. Eng. Technol. (IJIET)* **2016**, *7*, 285–288.
52. Sendra, S.; Parra, L.; Lloret, J.; Tomás, J. Smart system for children’s chronic illness monitoring. *Inf. Fusion* **2018**, *40*, 76–86. [[CrossRef](#)]
53. Mukhopadhyay, S.C. Wearable sensors for human activity monitoring: A review. *IEEE Sensors J.* **2014**, *15*, 1321–1330. [[CrossRef](#)]
54. Kumari, P.; Mathew, L.; Syal, P. Increasing trend of wearables and multimodal interface for human activity monitoring: A review. *Biosens. Bioelectron.* **2017**, *90*, 298–307. [[CrossRef](#)]
55. Singh, D.; Merdivan, E.; Psychoula, I.; Kropf, J.; Hanke, S.; Geist, M.; Holzinger, A. Human activity recognition using recurrent neural networks. In Proceedings of the International Cross-Domain Conference for Machine Learning and Knowledge Extraction, Reggio, Italy, 29 August–1 September 2017.
56. Chen, Y.; Zhong, K.; Zhang, J.; Sun, Q.; Zhao, X. LSTM networks for mobile human activity recognition. In Proceedings of the 2016 International Conference on Artificial Intelligence: Technologies and Applications, Bangkok, Thailand, 24–25 January 2016; Atlantis Press, Amsterdam, The Netherlands, 2016.
57. Ordóñez, F.J.; Roggen, D. Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors* **2016**, *16*, 115. [[CrossRef](#)] [[PubMed](#)]
58. Tapia, E.M.; Intille, S.S.; Larson, K. Activity recognition in the home using simple and ubiquitous sensors. In Proceedings of the International Conference on Pervasive Computing, Linz/Vienna, Austria, 21–23 April 2004.
59. Bao, L.; Intille, S.S. Activity recognition from user-annotated acceleration data. In Proceedings of the International Conference on Pervasive Computing, Linz/Vienna, Austria, 21–23 April 2004.
60. Duong, T.V.; Bui, H.H.; Phung, D.Q.; Venkatesh, S. Activity recognition and abnormality detection with the switching hidden semi-markov model. In Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05), San Diego, CA, USA, 21–23 September 2005.
61. Wu, W.; Dasgupta, S.; Ramirez, E.E.; Peterson, C.; Norman, G.J. Classification accuracies of physical activities using smartphone motion sensors. *J. Med. Internet Res.* **2012**, *14*, E130. [[CrossRef](#)]
62. Zhu, Y.; Nayak, N.M.; Roy-Chowdhury, A. Context-aware activity recognition and anomaly detection in video. *IEEE J. Sel. Top. Signal Process.* **2012**, *7*, 91–101. [[CrossRef](#)]
63. Plötz, T.; Hammerla, N.Y.; Olivier, P.L. Feature learning for activity recognition in ubiquitous computing. In Proceedings of the Twenty-Second International Joint Conference on Artificial Intelligence, Barcelona, Spain, 16–22 July 2011.
64. Wile, D.J.; Ranawaya, R.; Kiss, Z.H.T. Smart watch accelerometry for analysis and diagnosis of tremor. *J. Neurosci. Methods* **2014**, *230*, 1–4. [[CrossRef](#)]
65. Karakaya, M.; Şengül, G.; Bostan, A. Remotely Monitoring Activities of the Elders Using Smart Watches. *Int. J. Sci. Res. Inf. Syst. Eng.* **2017**, *3*, 56.

66. Maglogiannis, I.; Ioannou, C.; Spyroglou, G.; Tsanakas, P. Fall detection using commodity smart watch and smart phone. In Proceedings of the IFIP International Conference on Artificial Intelligence Applications and Innovations, Rhodes, Greece, 19–21 September 2014.
67. Siriwan, K.; Chanapai, N.; Hnusawan, B. Smart health monitoring system with IoT. In Proceedings of the 2018 IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE), Penang Island, Malaysia, 28–29 April 2018.
68. Asada, H.H.; Jiang, Ho.; Gibbs, P. Active noise cancellation using MEMS accelerometers for motion-tolerant wearable bio-sensors. In Proceedings of the 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, San Francisco, CA, USA, 1–5 September 2004.
69. Reynolds, D.A. Gaussian Mixture Models. *Encycl. Biom.* **2009**, *741*, 196. [[CrossRef](#)]
70. Rasmussen, C. The infinite Gaussian mixture model. *Adv. Neural Inf. Process. Syst.* **1999**, *12*, 554–560.
71. Zivkovic, Z. Improved adaptive Gaussian mixture model for background subtraction. In Proceedings of the 17th International Conference on Pattern Recognition, Cambridge, UK, 23–26 August 2004.
72. Zong, B.; Song, Q.; Min, M.R.; Cheng, W.; Lumezanu, C.; Cho, D.; Chen, H. Deep autoencoding gaussian mixture model for unsupervised anomaly detection. In Proceedings of the International Conference on Learning Representations, Vancouver, BC, Canada, 30 April–3 May 2018.
73. Laxhammar, R.; Falkman, G.; Sviestins, E. Anomaly detection in sea traffic—A comparison of the gaussian mixture model and the kernel density estimator. In Proceedings of the 2009 12th International Conference on Information Fusion, Seattle, WA, USA, 6–9 July 2009.
74. Li, L.; Hansman, R.J.; Palacios, R.; Welsch, R. Anomaly detection via a Gaussian Mixture Model for flight operation and safety monitoring. *Transp. Res. Part C Emerg. Technol.* **2016**, *64*, 45–57. [[CrossRef](#)]
75. Casado-Vara, R.; Chamoso, P.; De la Prieta, F.; Prieto, J.; Corchado, J.M. Non-linear adaptive closed-loop control system for improved efficiency in IoT-blockchain management. *Inf. Fusion* **2019**, *49*, 227–239. [[CrossRef](#)]
76. Casado-Vara, R.; Novais, P.; Gil, A.B.; Prieto, J.; Corchado, J.M. Distributed continuous-time fault estimation control for multiple devices in IoT networks. *IEEE Access* **2019**, *7*, 11972–11984. [[CrossRef](#)]
77. Chamoso, P.; González-Briones, A.; Rivas, A.; De La Prieta, F.; Corchado, J.M. Social computing in currency exchange. *Knowl. Inf. Syst.* **2019**, *61*, 733–753. [[CrossRef](#)]
78. Casado-Vara, R.; Prieto-Castrillo, F.; Corchado, J.M. A game theory approach for cooperative control to improve data quality and false data detection in WSN. *Int. J. Robust Nonlinear Control.* **2018**, *28*, 5087–5102. [[CrossRef](#)]
79. Chamoso, P.; Rodríguez, S.; de la Prieta, F.; Bajo, J. Classification of retinal vessels using a collaborative agent-based architecture. *AI Commun.* **2018**, *31*, 427–444. [[CrossRef](#)]
80. Chamoso, P.; González-Briones, A.; Rodríguez, S.; Corchado, J.M. Tendencies of technologies and platforms in smart cities: A state-of-the-art review. *Wirel. Commun. Mob. Comput.* **2018**, *2018*, 3086854. [[CrossRef](#)]
81. Sánchez, M.; Rodriguez, C.; Manuel, J. Smart Protective Protection Equipment for an accessible work environment and occupational hazard prevention. In Proceedings of the 2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence), Noida, India, 29–31 January 2020.
82. Márquez Sánchez, S.; Lecumberri, F.; Sati, V.; Arora, A.; Shoeibi, N.; Rodríguez, S.; Rodríguez, J.M.C. Edge Computing Driven Smart Personal Protective System Deployed on NVIDIA Jetson and Integrated with ROS. In Proceedings of the International Conference on Practical Applications of Agents and Multi-Agent Systems, L'Aquila, Italy, 7–9 October 2020.
83. Nelson, E.C.; Verhagen, T.; Noordzij, M.L. Health empowerment through activity trackers: An empirical smart wristband study. *Comput. Hum. Behav.* **2016**, *62*, 364–374. [[CrossRef](#)]
84. Bandura, A. Social cognitive theory of self-regulation. *Organ. Behav. Hum. Decis. Process.* **1991**, *50*, 248–287. [[CrossRef](#)]
85. Kim, K.J.; Shin, D. An acceptance model for smart watches. *Internet Res.* **2015**, *25*, 527–541. [[CrossRef](#)]
86. Sundermeyer, M.; Schlüter, R.; Ney, H. LSTM neural networks for language modeling. In Proceedings of the Thirteenth Annual Conference Of The International Speech Communication Association, Portland, OR, USA, 9–13 September 2012.
87. Ketkar, N.; Santana, E. *Deep Learning with Python*; Springer: Berlin/Heidelberg, Germany, 2017.
88. Data Augmentation Strategies for Time Series Forecasting. Available online: <https://stats.stackexchange.com/q/320952> (accessed on 10 May 2021).
89. Jain, A.K. Data clustering: 50 years beyond K-means. *Pattern Recognit. Lett.* **2010**, *31*, 651–666. [[CrossRef](#)]
90. Bishop, C. *Pattern Recognition and Machine Learning*; Springer: Berlin/Heidelberg, Germany, 2006.
91. Hammerla, N.Y.; Halloran, S.; Plötz, T. Deep, convolutional, and recurrent models for human activity recognition using wearables. *arXiv* **2016**, arXiv:1604.08880.

4.3. Intelligent Platform Based on Smart PPE for Safety in Workplaces

4.3.1. Información de la publicación

Título: Intelligent Platform Based on Smart PPE for Safety in Workplaces

Autores: Sergio Márquez Sánchez^{a,b}, Israel Campero Jurado^c, Jorge Herrera Santos^a, Sara Rodríguez González^a, Juan Manuel Corchado Rodríguez^{a,b,d,e}.

Afiliaciones:

^a BISITE Research Group, University of Salamanca, Edificio I+D+i, C/ Espejo, Salamanca 37007, Spain.

^b Air Institute, IoT Digital Innovation Hub (Spain), 37188 Salamanca, Spain

^c Department of Mathematics and Computer Science, Eindhoven University of Technology, 5600MB Eindhoven, The Netherlands

^d Department of Electronics, Information and Communication, Faculty of Engineering, Osaka Institute of Technology, Osaka 535-8585, Japan

^e Faculty of Creative Technology & Heritage, Universiti Malaysia Kelantan, Locked Bag 01, 16300 Bachok, Malaysia **Publicado en:** *Sensors 2021, 21(14), 4652. Special Issue Edge Computing Architectures in Industry 4.0*

D.O.I.: <https://doi.org/10.3390/s21144652>

Fecha de publicación: 7 Julio 2021.

Factor de Impacto: 3.576 – Q1 (2020).

4.3.2. Introducción

Los recientes avances tecnológicos han revolucionado la tecnología wearable, permitiendo que el número de aplicaciones y formatos de wearables no haya dejado de aumentar en los últimos años. La disponibilidad y la aptitud de las tecnologías wearables, así como su capacidad para formar parte de la vida cotidiana de cualquier individuo, las convierten en el candidato perfecto para la implantación de equipos de protección individual en el entorno laboral. Por otro lado, los sistemas de IA en los que se introducen mecanismos de aprendizaje, basan su planteamiento en un conjunto de reglas que, combinadas con el

conocimiento almacenado obtenido a partir de soluciones a problemas conocidos, tratan de predecir el resultado de experimentos inéditos. Gracias al uso de redes neuronales (NN) (Yegnanarayana, 2009), sistemas de razonamiento basado en casos (CBR) (Leake, 1996), aprendizaje profundo (DL) (Goodfellow et al., 2016) o algoritmos neuro-simbólicos híbridos (Riverola & Corchado, 2000) se permite al sistema determinar si una situación determinada supone un riesgo, en función de determinadas condiciones de contorno. En vista de ello, la implantación de un sistema electrónico de detección de anomalías en el puesto de trabajo puede ser un apoyo esencial para el cuidado del personal.

En este trabajo se propone la detección de anomalías a través de tres dispositivos: un casco (Campero-Jurado et al., 2020), un cinturón (Rodríguez & Corchado, 2020), y una pulsera (Márquez-Sánchez, Campero-Jurado, Robles-Camarillo, et al., 2021). La plataforma Edge-AIoT propuesta combina las tecnologías IoT, wearables, Edge Computing con Inteligencia Artificial para la toma de decisiones, suponiendo una enorme evolución en la seguridad y la Prevención de Riesgos Laborales. Contemplando así los objetivos específicos (OB5) y (OB6).

Una de las principales motivaciones de este trabajo es el uso del Edge Computing (OB7). Esta capa permite procesar la información de los diferentes dispositivos, aplicando algoritmos inteligentes para la detección temprana de anomalías y preprocesando los datos antes de ser enviados a la Nube. Se comparan diferentes modelos de inteligencia artificial. En el artículo anterior (Márquez-Sánchez, Campero-Jurado, Robles-Camarillo, et al., 2021) se incluía el uso de modelos como las Redes Neuronales Convolucionales Long short-term memory network (LSTM) para el comportamiento de las actividades industriales, los Modelos Gaussianos GMM para la detección de caídas y el envío de alarmas para respuestas rápidas. En este caso, los modelos se relacionaron a través de heurísticas, donde se propone interpretar la salida de cada modelo como un grafo. Donde, finalmente una máquina de vectores de soporte ponderó los votos de los modelos y se mostró su validación (OB8). Los modelos basados en redes complejas han mostrado grandes avances en los últimos años, y en nuestro estudio se comprueba su efectividad en la interpretación de la información.

4.3.3. Objetivos

El trabajo publicado se encuadra dentro de las diferentes investigaciones y experimentaciones que se han llevado a cabo en cuanto al diseño e implementación de una plataforma de gestión de PRL con un diseño Edge-AIoT, así como la experimentación y validación de dicha plataforma en entornos reales. En este sentido, tal y como queda definido en los Objetivos Específicos en el Capítulo 1, para esta publicación se establecieron los siguientes objetivos:

- Investigar sobre técnicas y metodologías sobre el tratamiento de los datos recogidos en los sensores. Uso de análisis de datos, algoritmos de prevención y el uso de la plataforma de control.
- Integrar las prestaciones que proporciona el AIoT y Smart Data para obtener una plataforma de apoyo en el desempeño de la actividad, capaz de evolucionar y aprender.
- Diseño de la evolución de una plataforma modular Edge AIoT escalable, para la ingestión de datos de diferentes dispositivos, que incorpore algoritmos de Inteligencia Artificial para la detección, diagnóstico y el control predictivo de situaciones de riesgo en entornos laborales.
- Validar nuevos mecanismos inteligentes en diferentes entornos de trabajo para el análisis y evaluación del correcto desempeño de los resultados obtenidos.

4.3.4. Conclusiones

Los requisitos legales obligan a las empresas a realizar importantes inversiones en equipos de protección, un área en la que se esfuerzan por destacar entre sus competidores y cumplir con la normativa a un coste razonable. Por este motivo, el uso de las tecnologías presentadas en esta plataforma Edge-AIoT permiten mejorar la capacidad predictiva del sistema electrónico, situándose como un paso esencial para la mejora de los equipos mediante la implementación de tecnologías emergentes en el hardware de los EPI (Sun & Ansari, 2016).

El desarrollo de esta herramienta inteligente para la PRL, ha demostrado ha generado buenos resultados en la combinación de modelos AI como redes neuronales convolucionales - Deep Convolutional Neural Network, Long short-term memory network (LSTM), modelos de Mezclas Gaussianas - Gaussian Mixture Model (GMM). Donde finalmente una máquina de vectores de soporte ponderó los votos de los modelos.

Gracias a la plataforma, se genera un ecosistema para dar recomendaciones y evaluar los riesgos, que es una acción de importancia crítica en el desarrollo de un eficaz plan de PRL. La integración de este tipo de sistemas inteligentes permite actualizar de forma automática en base a la información recogida, registrando diferentes variables y ponderando un conjunto de indicadores en función de la incidencia que presentan en el desencadenamientos de determinados escenarios. Generando un sistema de predicción, gestión de alertas y apoyo a la toma de decisiones, anticipando situaciones de riesgo y proponiendo respuestas acordes a las condiciones de contorno.

4.3.5. Publicación original



Article

Intelligent Platform Based on Smart PPE for Safety in Workplaces

Sergio Márquez-Sánchez ^{1,2,*†}, Israel Campero-Jurado ^{3,†}, Jorge Herrera-Santos ¹, Sara Rodríguez ¹ and Juan M. Corchado ^{1,2,4,5}

- ¹ BISITE Research Group, University of Salamanca, Calle Espejo s/n, Edificio Multiusos I+D+i, 37007 Salamanca, Spain; jorgehsmp@usal.es (J.H.-S.); srg@usal.es (S.R.); corchado@usal.es (J.M.C.)
² Air Institute, IoT Digital Innovation Hub (Spain), 37188 Salamanca, Spain
³ Department of Mathematics and Computer Science, Eindhoven University of Technology, 5600MB Eindhoven, The Netherlands; i.campero.jurado@tue.nl
⁴ Department of Electronics, Information and Communication, Faculty of Engineering, Osaka Institute of Technology, Osaka 535-8585, Japan
⁵ Faculty of Creative Technology & Heritage, Universiti Malaysia Kelantan, Locked Bag 01, Bachok, Kota Bharu 16300, Kelantan, Malaysia
- * Correspondence: smarquez@usal.es; Tel.: +34-685-043-554
† These authors contributed equally to this work.

Abstract: It is estimated that we spend one-third of our lives at work. It is therefore vital to adapt traditional equipment and systems used in the working environment to the new technological paradigm so that the industry is connected and, at the same time, workers are as safe and protected as possible. Thanks to Smart Personal Protective Equipment (PPE) and wearable technologies, information about the workers and their environment can be extracted to reduce the rate of accidents and occupational illness, leading to a significant improvement. This article proposes an architecture that employs three pieces of PPE: a helmet, a bracelet and a belt, which process the collected information using artificial intelligence (AI) techniques through edge computing. The proposed system guarantees the workers' safety and integrity through the early prediction and notification of anomalies detected in their environment. Models such as convolutional neural networks, long short-term memory, Gaussian Models were joined by interpreting the information with a graph, where different heuristics were used to weight the outputs as a whole, where finally a support vector machine weighted the votes of the models with an area under the curve of 0.81.



Citation: Márquez-Sánchez, S.; Campero-Jurado, I.; Herrera-Santos, J.; Rodríguez, S.; Corchado, J.M. Intelligent Platform Based on Smart PPE for Safety in Workplaces. *Sensors* **2021**, *21*, 4652. <https://doi.org/10.3390/s21144652>

Academic Editor: Fatos Xhafa

Received: 30 April 2021

Accepted: 30 June 2021

Published: 7 July 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction and Motivation

There is a necessity to mitigate the high number of fatalities reported in recent years in the work environment. Different industries such as construction, mining or electricity have begun to invest in improving their employees' safety by integrating new technologies or "smart technologies" in the work environment. These technologies are responsible for monitoring and protecting individuals in a work area. The integration of these systems aims to create an ecosystem of PPE to preserve the workers' integrity. Such equipment must be adapted to the workers' needs; providing protection without impeding them from performing their tasks as normal. This aspect is crucial for an effective application of the systems, as an uncomfortable or bulky device would discourage workers from its use. Therefore, the technology best suited to these requirements is wearable technology, which allows it to be worn as another accessory or garment. The International Labour Organisation (ILO) estimates that some 2.3 million persons around the world succumb to work-related accidents or diseases every year; this corresponds to over 6000 deaths every single day. Worldwide, there are around 340 million occupational accidents and

160 million victims of work-related illnesses annually, and the updates indicate an increase of accidents and ill health. However, statistics show that the injuries of workers may vary depending on their gender and nationality. First-world countries with more regulations and less dangerous jobs have a lower death rate compared with underdeveloped countries that also tend to not track workplace injuries or fatalities [1]. For example, in the United States, the incidence rate for total Occupational Safety and Health Administration (OSHA) recordable cases remained at 2.8 per 100 full-time workers and a total of 5333 occupational fatalities were recorded in 2019 according to the United States Bureau of Labor Statistics. This makes it necessary to research and develop technologies that replace or protect individuals at work. The impact of safety laws, safety programs regulations and occupational injury record-keeping regulations is of great importance. Effective rules and standards can significantly reduce accident and injury rates, consequently affecting business and the economy [2]. Different studies show the importance of state and federal agencies considering adopting workplace safety regulations [3] because of the impact these laws have on the frequency of reported workplace injuries and the consequent improvement of workers' conditions [4].

Recent technological advances have revolutionised wearable technology, especially in 2002 when Bluetooth connectivity enabled wireless interaction between devices and has seen tremendous expansion over the last two decades [5,6]. With the market growing continuously, the number of such wearable applications and formats has been increasing steadily. Considering the availability and feasibility of wearable technologies and their ability to be an integral part of any individual's daily life, they are the perfect candidate for the deployment of personal protective equipment in the work environment. The wearables on the market have adapted to the requirements of different niches. Understandably, not all of these adaptations were met with commercial success, either because the target population was not big enough or because of the existence of other more ergonomic solutions.

In recent years, the availability of wearable Internet of Things (IoT) devices has increased due to the cost reduction in technology production and making them more accessible to the public, provoking a great interest in studying this topic among the scientific community. This accessibility coupled with the IoT revolution allows us to gain access to some working environments' complex mechanics and react quickly to imminent danger. IoT are networks of physical objects that implement technologies such as electronic circuits. Software, sensors, actuators, and network connectivity allow these objects to collect and exchange data for specific purposes [7]. Research has been carried out on equipment and auxiliary systems for detecting, warning and identifying risks, which can be integrated into different smart PPE. To this end, the different solutions that can be integrated in the device have been analysed, optimising the detection and prevention of risks, as well as the detection of the health conditions inherent to specific tasks in the workplace. All this is made possible thanks to the integration of sensors and actuators. Thus, an analysis has been made of the possibilities of adapting, developing and optimising existing technologies for: measuring anthropometric parameters, human activity recognition, real-time location systems and sensor networks. Thanks to the measurement of anthropometric parameters, the proposed bracelet is able to establish estimates of the worker's condition in real-time, where a set of determined biometric measures is within pre-set thresholds. In addition, the architecture of the solution and the blocks into which it is divided have been clearly defined. We can find many examples of smart Personal Protective Equipment (PPE) developments that can monitor vital signs and the parameters of the industrial environment. In the paragraphs that follow, the different ways in which wearables can be integrated into workplaces are described, and it is analysed how ecosystems of connected devices can help protect the individual [8–10].

PPE is used to extend the individual's capabilities and monitor their condition. For example, in professions such as fishing, warning and survival systems are integrated into protective clothing, including an artificial lung, flotation system and emergency light. The suit, which is highly visible in colour, alerts the rescue base station and gives the GPS

position of the suit. In the case of firefighters, suits have been developed that integrate vital and environmental sensors, which aim to monitor the individual remotely and provide information to the individual about their environment and alert them of potential dangers via an HUD [11–14].

Smart PEE is a project inspired by the Ebola epidemic in Africa during 2013–2016 and which has been revitalised by the current pandemic. The project aims to redesign the personal protective equipment used by health workers and essential personnel during pandemics. The protective suit consists of a single protective piece that seeks to facilitate the use of the suit and reduce contact when the individual dresses or undresses. The suit is equipped with temperature, humidity, and air quality sensors inside the suit, and an integrated ventilation system that aims to keep the individual at a comfortable temperature so that they can get dressed and undressed. The suit is equipped with sensors for temperature, humidity and air quality inside the suit, and an integrated ventilation system that regularly keeps the individual at a comfortable temperature and takes care of the air quality [15–17].

These proposals include devices that are similar to those analysed and modelled in this research. In this context, if we analyse the suppliers of this type of product, we find worldwide companies (3M, Siteandfield, General Electric, Honeywell, etc.) whose positioning has been developed over decades and which offer classic protective equipment (helmets, masks, gloves, smartwatch, detectors, etc.) of high quality, at a competitive price and which try to incorporate applications that offer some advanced functionality. In recent years, newer companies (DAQRI, Human Condition Safety, Intellinium, Seebo) have also become involved in this market and are committed to providing solutions that integrate new technologies, such as Big Data and ICT solutions, to enhance industry 4.0 with a special focus on worker safety and the maintenance of facilities [18–23].

Systems capable of monitoring the state of workers and the environment are needed to ensure safe conditions and can also be integrated with other lines related to production, enterprise resource planning (ERP), etc. There are few examples of platforms that provide comprehensive support to workers, and those that we do find are very industry-specific. Some developments integrate virtual organisation technologies for the fusion of information from multi-domain data sources or neural networks, fuzzy logic, Bayesian networks, decision trees and other hybrid inference and artificial intelligence techniques. In this regard, our platform intends to meet the needs of any industry through a modular and adaptable design, having the ability to interoperate different individual protection devices, allowing for real-time visualisation and early detection of any anomaly using artificial intelligence. The platform incorporates a smart data system capable of providing intelligent responses, fusion algorithms and data mining processes of the different connected devices and a knowledge base that reduces the impact of anomalies.

Currently, there are platforms that use cloud architectures to process large amounts of data. Thanks to virtual agent organisations, the platform is modular and scalable, facilitating the incorporation of new vertical solutions integrated into the horizontal design of the city platform [24,25]. Likewise, with the use of technologies such as edge computing, it is possible to propose environments capable of processing information at the device level, carrying out pre-processing, eliminating noise as well as managing data more efficiently and rationally [26,27]. Similarly, the nodes can act autonomously, communicating with the platform on an ad hoc basis when their services are required. It also allows for the introduction of security layers between the platform and the nodes, which increases the reliability of the data. Thanks to the platform's complementary capabilities (information extraction and integration capabilities, capacity to learn and to generate new rules using the acquired knowledge, high capacity to process raw data), the quality of the obtained information is improved. They allow the system to not only process data but also to understand it when performing tasks [28].

The trend is to integrate smart data capabilities into the platform of edge computing environments, capable of processing and combining data from different sources, such as

ERP, manufacturing operation management (MOM), computerised maintenance management system (CMMS), supervisory control and data acquisition (SCADA), industrial Internet of Things (IIoT), vibrations, noise or incident reports in real-time. This capacity may be integrated with other technological innovations, such as cognitive systems, which are developed through the application of artificial intelligence to data, convolutional neural networks (CNN) and deep reinforcement learning (DRL), making it possible to build tools capable of controlling an enormous set of parameters related to processes and the environment. The aim is to gain exhaustive knowledge of the situation and incorporate intelligent mechanisms to optimise processes, maintenance and safety [29–35].

Regarding artificial intelligence models, the problem of maintenance and occupational safety in the industry has also been approached in different ways. Typically, the systems responsible for the safety of workers are designed to meet the specific needs of a company and tend to react to measured stimuli, provided that these reach a minimum threshold (action-reaction), which presents little capacity to adapt or modify behaviour in the face of new situations. On the other hand, AI systems in which learning mechanisms are introduced base their approach on a set of rules that, combined with stored knowledge obtained from solutions to known problems, try to predict the outcome of unpublished experiments. The use of neural networks (NN) [36], case-based reasoning (CBR) systems [37], deep learning (DL) [38] or hybrid neuro-symbolic algorithms [39] allow the system to determine whether a given situation poses a risk, depending on certain boundary conditions (the normal operation of a machine can pose a risk to a worker under certain circumstances and these do not necessarily have to be static).

Likewise, in different works focused on complex networks [40,41], it has been demonstrated that the analysis of information in the form of graphs allows a more complete structuring since non-linear information can be treated intuitively, which is why it has been proposed to transfer various machine learning techniques to complex networks, where links between pairs of nodes or relationships can be predicted based on previous information. For this purpose, heuristics well known in fields such as biology or computer science have been used.

From the above, it can be concluded that the use of technologies such as wearables, IoT, edge computing combined with wireless communications and artificial intelligence for decision making can bring about a significant evolution in safety and occupational risk prevention. In view of this, the implementation of an electronic system for the detection of anomalies in the workplace can be an essential support for the care of personnel. In this paper, we propose anomaly detection through three devices: a helmet [8], a belt [42], and a bracelet [43]. One of the main motivations of this work is the use of edge computing. This layer allows to process the information from the different devices, applying intelligent algorithms for the early detection of anomalies and pre-processing the data before being sent to the Cloud. Different artificial intelligence models are compared. Our previous work included the use of models such as convolutional neural networks, long short-term memory for the behaviour of industrial activities, Gaussian models for fall detection and alarm dispatching for fast responses. The models were linked through heuristics, where firstly it was proposed to interpret each model output as a graph. Models based on complex networks have shown great progress in recent years, so it was decided to interpret the information in that way, where finally, a support vector machine weighted the votes of the models and its validation was shown.

The remaining part of this research is organised as follows: Section 2 presents an overview of the related literature. Section 3 details the system design and the developed devices. Section 4 presents the data analysis as well as the union of the different models for the final answer. Finally, in the last section, we present some conclusive remarks and future lines of research.

The advantages and disadvantages of our paper with respect to other similar works have been included in Table 1, also showing the main technologies used in these works.

Table 1. Proposals related to similar technologies and platforms.

Bibliography	Technologies Included	Advantages and Disadvantages	Novelty of the Proposal
Heras, Stella, et al. (2012)	Cloud computing,	This work is focused on the use of multi-agent systems and cloud computing, so our platform provides additional functionality.	It presents the role of argumentation in the next generation of agreement technologies and their use in cloud computing environments.
Shawish, Ahmed, and Maria Salama. (2014)	Distributed systems, Multi-agent systems, Virtual organisations Social Computing	It classifies the Cloud's deployment and service models, providing a complete description of the Cloud services vendors.	It provides a comprehensive overview of the Cloud's anatomy, definition, characteristic, effects, architecture, and core technology.
Chamoso, Pablo, et al. (2019)		Improves interaction between users and ensures a fast and secure operation.	A multi-agent system is the base of the developed software; MAS is an essential and commonly used tool in social computing.
Chamoso, Pablo, et al. (2016)		The system provides a web application to manage all the review processes for power lines management.	This work is focused on the periodic review of transmission towers (TT) to avoid important risks, such as step and touch potentials, for humans.
Riverola, Florentino Fdez, et al. (2000)	Hybrid neuro-symbolic systems, Case-based reasoning (CBR), Artificial Neural Networks (NN)	Classifications of these systems, paying particular attention to each subsystem's distinctive features that make up the hybrid models.	This work is a general review of hybrid neuro-symbolic artificial intelligence systems, focusing on those composed of artificial intelligence.
Van Den Oord, Aáron, et al. (2013)	Agent Virtual organisation, Deep Learning	Deep content-based focus on music.	This work is aimed at a platform based on music recommendation through deep learning.
Chen, Zhen-Yao, et al. (2017)		A hybrid of genetic algorithm and artificial immune system (HGAI) algorithm.	Evolutionary algorithm-based radial basis function neural network training for industrial personal computer sales forecasting.
Puig Ramírez, Joaquim. (2010)	Predictive maintenance, Machine Train Monitoring,	The reliable detection and anticipation of performance deviations via monitoring the production and product-related process, diagnostic of possible causes and predicting the time of occurrence.	Asset optimisation and predictive maintenance in discrete manufacturing industry.
Mobley, R. Keith. (2002)	Industrial organisation, Production control, Supervision	The system provides maintenance methods in manufacturing or production plans.	It is a review of the methods and methodologies for carrying out predictive maintenance in industries.
Sittón, Inés, et al. (2017)		It is aimed at the recognition and extraction of unstructured data patterns from IoT sensors.	Pattern extraction for the design of predictive models in Industry 4.0
Shin, D. et al. (2016)	Edge computing,	Use of edge computing, followed by several case studies, ranging from cloud offloading to smart home and city.	It presents several challenges and opportunities in the field of edge computing.
Shi, Weisong and Schahram Dustdar. (2016)	Real-time monitoring, Internet of Things (IoT), Protective System	The success of the Internet of Things and rich cloud services have helped create edge computing.	This work is aimed at understanding edge computing technology and its multitude of applications to propose environments capable of processing information at the device level.
Satyanarayanan, Mahadev. (2017)	Smart cities and home	Industry investment and research interest in edge computing.	It presents several research and opportunities in the field of edge computing.

Table 1. *Cont.*

Bibliography	Technologies Included	Advantages and Disadvantages	Novelty of the Proposal
Sánchez, Sergio Márquez, et al. (2020)		The paper is before work that is supported by the current platform work based on ROS.	This work is based on edge computing Driven Smart Personal Protective System Deployed on NVIDIA Jetson and Integrated with ROS.
Sun, Xiang, and Nirwan Ansari. (2016)		A hierarchical fog computing architecture in each fog node to provide flexible IoT services while maintaining user privacy.	Mobile edge computing for the Internet of Things.
Podgorski, Daniel, et al. (2017)	Ambient intelligence (AI),	A new conceptual framework for dynamic Occupational Safety and Health (OSH) management in Smart Working Environments (SWE)	A proposed framework is based on a new paradigm of OSH risk management consisting of real-time risk assessment and the capacity to monitor the risk level of each worker individually.
Boyes, Hugh, et al. (2018)	Industrial Internet of Things (IIoT), Smart working environment (SWE), Occupational safety management,	It is focused on analyses related to partial IoT taxonomies.	It develops an analysis framework for IIoT that can be used to enumerate and characterise IIoT devices.
Sánchez, Sergio Márquez, (2019)	Personal Protective Equipment (PPE), Cyber-physical systems, Real-time risk assessment,	They seek to improve the health and safety of work sectors where there is a high risk of an accident.	Solutions made available by industry 4.0 to prevent hazards with a wireless model consists of the design of different innovative PPE.
Chae, Hye Seon, et al. (2017)		Smart personal protection equipment uses various biometric information from the combination of devices to allow the wearer to voluntarily recognize the danger	The research and development of the rural smart personalisation equipment for preventing farming and disaster prevention

2. Platform Design

Currently, companies in the industrial sector focus their efforts on incorporating the advances included in the Industry 4.0 model to continue competing in an increasingly high-tech market. This proposal includes the development of a control and visualisation platform that integrates hybrid artificial intelligence algorithms to detect and prevent risks and accidents. As part of the development, different devices have also been developed that are connected to the platform for identifying risk situations so that the worker can be notified. The proposed system [22] is based on an architecture where there is a concentrator node consisting of a NVIDIA Jetson Nano, which is responsible for collecting the measurements received by the different devices in JSON format. Through communication with the Mosquitto server with MQTT communication protocol, the data will be sent to the remote server, reducing the sending rate to the essential data, thus deploying an edge computing system. The devices that have been developed are a helmet, belt and bracelet, which can be integrated into the platform to carry out the data analysis. As the data logger, we ideally use a NVIDIA Jetson Nano as an IoT edge device because it is a powerful low-power board, which allows carrying out intensive computations of algorithms based on machine learning. The described system can be seen in the following Figure 1 where there are three distinct layers. In the lower layer of devices, data collection and detection of individual alarms is carried out separately for each device. Subsequently, it communicates via WiFi with the intermediate layer in which data are collected from each one. In this layer, edge computing technology is used; all the system information is processed, applying intelligent algorithms to this layer for the early detection of anomalies and pre-processing the data before being sent to the Cloud in an orderly manner. Finally, the information is received in a Cloud environment for the visualisation of the data from the platform and the application of deep learning models to detect possible anomalies thanks to the training of the set of data ingested historically.

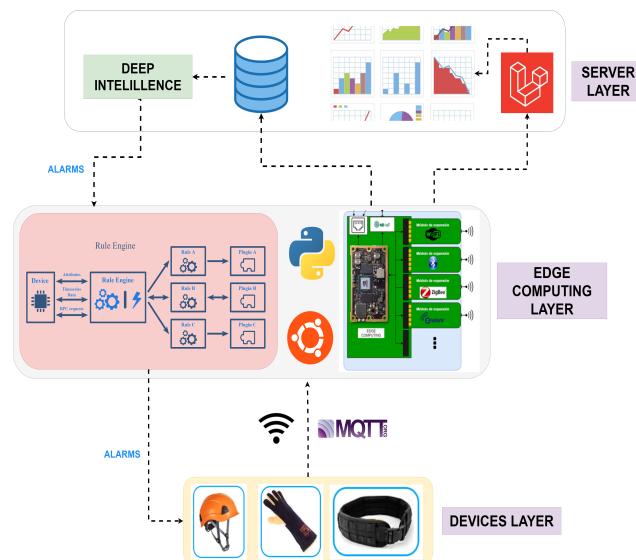


Figure 1. System architecture.

If we consider the hardware part within the different layers, simple rules have been implemented in each device's firmware that alerts in real-time if any value has exceeded the limit value. On the other hand, in the concentrator node or gateway edge computing, advanced data processing is carried out, applying machine learning techniques and intelligent artificial intelligence algorithms. With them, we can detect if, based on all the

information collected and historical data, an alert could be detected. In addition, we pre-process the data before sending it to the Cloud for visualisation. Therefore, concerning the devices and the Cloud server, this node acquires a fog computing node characteristic in the overall system.

These components are integrated with each other in order to provide monitoring of the operator's environmental conditions. The information transmission component is an ESP32 module in each of them, which integrates WiFi technology in order to transmit the information collected from the components described above to a local server. The logical viewpoint of the electronic system collects information from the components responsible for monitoring the worker's environment as well as the energy percentage of the lithium battery, as shown in Figure 2. After collecting the information, it is transmitted to the NVIDIA Jetson Nano via JSON. Likewise, with the aim of notifying the worker previously about the detected anomaly, threshold values are established to report the anomaly detected in the first instance. If the anomaly is confirmed, the information is retransmitted to the electronic system, being notified more frequently by the device. The power supply is provided in all the modules by a 3.7 V Lipo battery, connected to the power module. It should be noted that specific sensors integrated into the devices are repeated, as is the case of the Square Force-Sensitive Resistor (FSR), which, when placed in the helmet, allows us to detect whether we are wearing it and the impacts. On the other hand, the bracelet allows the operator to activate an alarm when it is pressed. In addition, the IMUs are repeated in all the devices to measure falls and impacts, using MPU6050 in the helmet and belt, and BMI160 in the bracelet. The derived advantages are that we will have more information for training and accident detection in the system. In addition, we will be able to have the functionality of reading and fall detection using the devices separately.

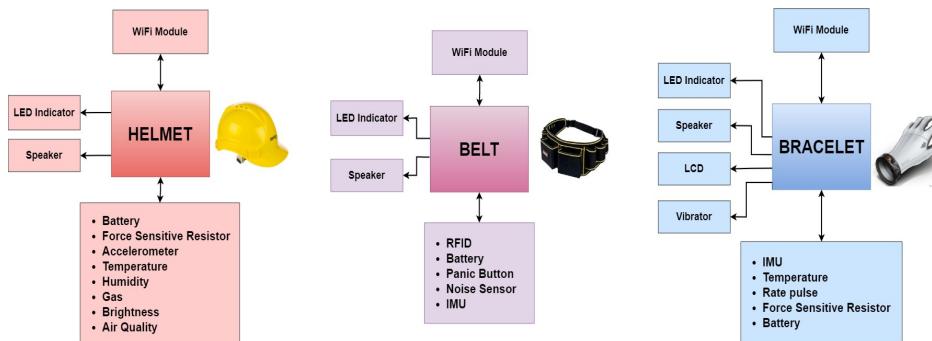


Figure 2. Devices diagram [8,42,43].

The Smart PPE helmet protects the operator from possible impacts while monitoring variables in their environment, such as light, humidity, temperature, atmospheric pressure, presence of gases, and air quality. At the same time, the smart PPE is to be bright enough to be seen by other workers, and the light source will provide a different vision to the operator [8]. The component used to supervise gas, harmful gases, pressure, temperature and humidity is the environmental sensor BME680. It is a micro-electromechanical system (MEMS) that integrates a volatile organic compounds (VOC) sensor, temperature sensor, humidity sensor and barometer. The sensor implemented for the monitoring of the level of brightness is the ALS-PT19 ambient light sensor. The sensor implemented for shock detection is a sensitive force resistor. The sensor responsible for detecting falls suffered by the worker is the MPU6050 module, an electronic component with six axes. The light source integrated into the helmet is a multicolour NeoPixel Adafruit LED strip, which will light up in a different colour depending on the alarm or the environment's state. Figure 3 shows the helmet with the electronics installed and the display panel for the different parameters it measures.

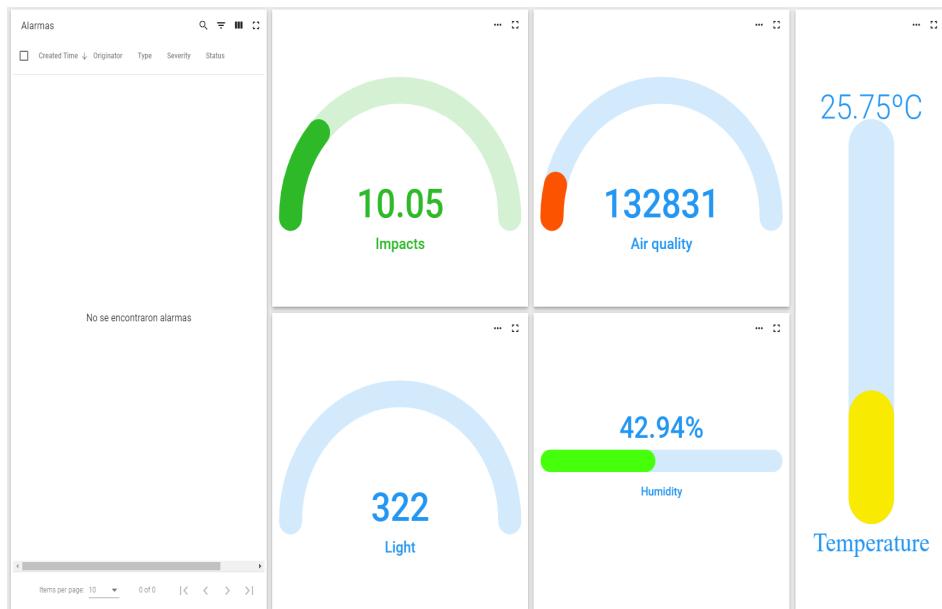


Figure 3. Platform helmet alarm panel [8].

The Smart PPE bracelet consists of electronic components welded to a flexible protoboard. These are ESP32 with an LCD display, buzzer, LED strip and monitoring sensor composed by IMU, temperature sensor, pulse sensor and panic button. The objective is to favour the interaction and monitoring of the user and the environment. For human activity recognition (HAR), a BMI160 inertial sensor (IMU) from Bosch (Stuttgart, Germany) provides precise acceleration and angular rate (gyroscopic) measurement. We measured the user's body temperature through a Thermocouple Type-K Glass Braid Insulated Stainless Steel Tip from Adafruit (New York, NY, USA), which are best used for measuring surface temperatures. To measure the pulse rate, we used photodiode sensors, which have two light emitters and two light receivers and can measure the heartbeat, causing the reflected light to vary at each instant; this makes it possible to estimate the measurement of the pulses per minute. Figure 4 shows the bracelet with the panel and different sensor indicators.

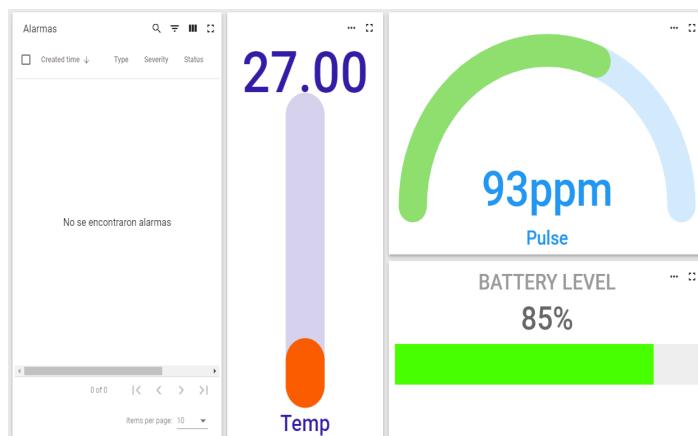


Figure 4. Platform bracelet alarm panel [43].

The belt is composed of electronics integrated on a single board for fall detection, noise level and also makes it possible for the worker to send a warning if an anomaly has been detected or if they are in danger. As with the helmet and bracelet, it communicates with the NVIDIA Jetson Nano for sensor data processing and performing alarm detection on the device itself. To detect falls, an MPU6050 accelerometer was used, which contains an accelerometer and a MEMS gyroscope. To measure high noise levels, a KY-038 sound sensor was used, which is a transducer that converts the sound waves into electrical signals, incorporating a microphone together with an LM393 comparator, which allows reading both an analogue and a digital value. In addition, an accessible panic button is located outside of the electrical enclosure to alert the operator of a possible accident and override a false alarm [42]. Figure 5 shows the belt with the panel and different sensor indicators.

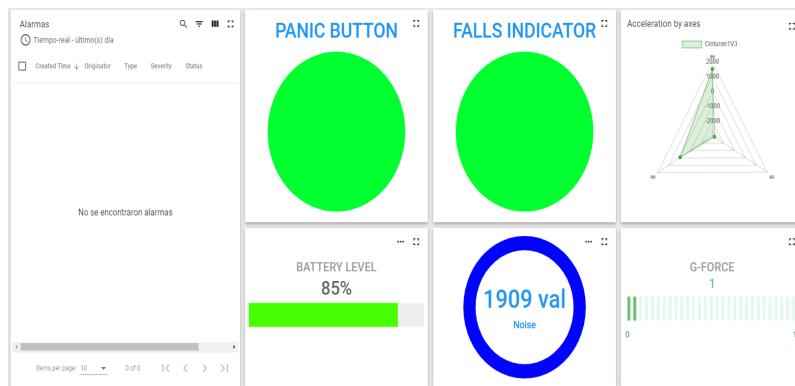


Figure 5. Platform belt alarm panel [42].

Table 2 shows the technical specifications of each of the electronic components selected for the device.

Table 2. Components technical specifications.

Device	Component	Characteristics	Description
Helmet	ALS-PT19 Ambient light sensor	<ul style="list-style-type: none"> - Supply Voltage: Vcc –0.5~6.0 V - Vce = 5 V, Ev = 1000 Lx - Color Temperature = 6500 K 	The ALS-PT19 is a low cost ambient light sensor, consisting of phototransistor in miniature SMD.
	MPU6050	<ul style="list-style-type: none"> - Supply Voltage, VDD –0.5 V to +6 V - Acceleration (Any Axis, unpowered) 10,000 g for 0.2 ms - Gyroscope Features: FSR of ± 250, ± 500, ± 1000, and $2000^\circ/\text{s}$ - Accelerometer Features: FSR ± 2 g, ± 4, ± 8 and ± 16 g - Nonlinearity (typ.) (A): 0.5% (G); 0.2% - Sensitivity Scale Factor: (G,typ) 131, 65.5, 32.8, 16.4 LSB ($^\circ/\text{s}$) (A,typ) 16.384 LSB/g, 8.192 LSB/g, 4.096 LSB/g, 2.048 LSB/g - Sensitivity Scale Factor Tolerance: (G) $\pm 3\%$ FSC: Full Scale Range 	The MPU6050 module contains a three-axis gyroscope with which we can measure angular velocity and a 3-axis accelerometer with which we measure the X, Y and Z components of the acceleration, the accelerometer works on the piezo electric principle, it also has a temperature sensor.
	NeoPixel Adafruit LED strip	<ul style="list-style-type: none"> - Supply Voltage: Vcc +6.0~+7.0 V - Low voltage output current: 18.5 mA and 10 mA (min) - Operation Frequency: 800 KHz 	Neopixel stick 8 × 5050 RGBW LEDs ~ 3000 K
	Square Force-Sensitive Resistor (FSR)	<ul style="list-style-type: none"> - Actuation Force ~ 0.2 N min - Force Sensitivity Range: ~ 0.2 N–20 N - Force Repeatability Single Part $+/- 2\%$ - Force Repeatability Part to Part $+/- 6\%$ (Single Batch) 	FSRs are sensors that allow you to detect physical pressure, squeezing and weight.

Table 2. Cont.

Device	Component	Characteristics	Description
BME680		<ul style="list-style-type: none"> - Digital interface I²C (up to 3.4 MHz) and SPI (3 and 4 wire, up to 10 MHz) - Supply voltage: VDD: 1.71 V to 3.6 V - VDDIO: 1.2 V to 3.6 V - Operating range –40–+85°C, 0–100% r.H., 300–1100 hPa 	The BME680 is a digital 4-in-1 sensor with gas, humidity, pressure and temperature measurement based on proven sensing principles.
Belt	MPU6050	<ul style="list-style-type: none"> - Supply Voltage, VDD –0.5 V to +6 V - Acceleration (Any Axis, unpowered) 10,000 g for 0.2 ms - Gyroscope Features: FSR of ±250, ±500, ±1000, and 2000°/s - Accelerometer Features: FSR ±2 g, ±4 g, ±8 g and ±16 g - Nonlinearity (typ.) (A): 0.5% (G): 0.2% - Sensitivity Scale Factor: (G.typ) 131, 65.5, 32.8, 16.4 LSB (°/s) (A.typ) 16,384 LSB/g, 8,192 LSB/g, 4,096 LSB/g, 2,048 LSB/g - Sensitivity Scale Factor Tolerance: (G) ±3% FSC: Full Scale Range 	The MPU6050 module contains a three-axis gyroscope with which we can measure angular velocity and a 3-axis accelerometer with which we measure the X, Y and Z components of the acceleration, the accelerometer works on the piezo-electric principle, it also has a temperature sensor.
Bracelet	KY-038 sensor	Analogue Signal, VDD: 3.3 V	Microphone sound sensor module
Bracelet	Thermocouple Type-K	<ul style="list-style-type: none"> - Precision: ±1 °C - Output range: –6 to 20 mV 	Glass braid insulated stainless steel tip, which can be used in high temperature.
Heart Rate Monitor Sensor		<ul style="list-style-type: none"> - Input Voltage (Vin): 3.3–6 V (5V recommended) - Output Voltage: 0 - Vin (Analogue), 0/ Vin (Digital) - Operating current: <10 mA 	It is based on PPG techniques, to detect blood volume changing in the microvascular bed of tissues.
BMI160 Inertial sensor (IMU)		<ul style="list-style-type: none"> - Sensitivity (typ.) Acc. ±2 g: 16,384, ±4 g: 8192, ±8 g: 4096, ±16 g: 2048 LSB/g - Sensitivity (typ.) Gyro. ±125°/s: 262.4, ±250°/s: 131.2, ±500°/s: 65.6 LSB/°/s - TCS (typ.) (A): ±0.03%/K (G): ±0.02%/K - Nonlinearity (typ.) (A): 0.5 %FS (G): 0.1 %FS - Offset (typ.) (A): ±40 mg (G): ±3°/s - TCO (typ.) (A): ±1.0 mg/K (G): 0.05°/s/K 	It is an inertial measurement unit (IMU) consisting of a state-of-art 3 axis, low-g accelerometer and a low power 3 axis gyroscope.
Square Force-Sensitive Resistor (FSR)		<ul style="list-style-type: none"> - Actuation Force ~0.2 N min - Force Sensitivity Range: ~0.2 N–20 N - Force Repeatability Single Part +/- 2% - Force Repeatability Part to Part +/- 6% (Single Batch) 	FSRs are sensors that allow you to detect physical pressure, squeezing and weight.

This set of devices forms an environment that, once deployed, monitors the position and status of machines and individuals, communication between employees, representation and analysis of data to prevent accidents and a real-time representation of the work environment through a remotely accessed digital model, Figure 6.

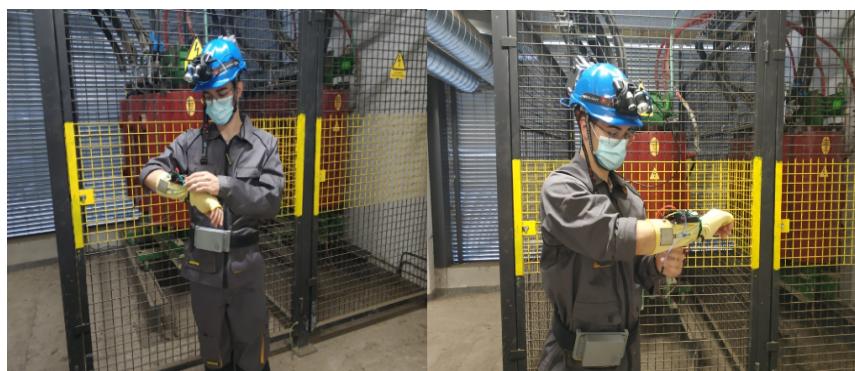


Figure 6. The configuration of the bracelet, helmet and belt.

3. Data Analysis and Modelling

As mentioned in the introduction, this section integrates the different proposals that have been made to ensure the safety of workers in hostile environments, which can also be implemented in medical areas in the future. Our work unites three previous proposals: the intelligent multisensor helmet, the belt that integrates data aligned by the Naive Bayes model, and a bracelet that works with a hybrid model of a long short-term memory neural network and a Gaussian mixture model.

The ultimate goal is to have a complete platform with well-defined safety equipment for monitoring the strategic areas of the body, to reduce response times to accidents or problems that may occur during work that involves risk. That is, we will propose a way to handle the results of the previous devices with their respective AI/ML models (currently the method of ensemble models AdaBoost and Stacking ensemble ML are well known), where our proposal is to perform the stacking of ML models and deep models by means of the representation of the information as a complex graph. This allows us to handle information with non-linear behaviour in a natural way, where, in the end, we are obtaining a voting of the information as any other ensemble model would do.

3.1. Helmet

The smart helmet described in [8] is a piece of security equipment in which a comparison of different machine learning models was carried out to find an adaptable one for the analysis of human activity behaviour. The training dataset consisted of 11,755 samples and 12 different scenarios, the use of a deep convolutional neural network (ConvNet/CNN) is proposed for the detection of possible occupational risks, the CNN had an accuracy of 92.05% in cross-validation. This work was proposed to work with 2-D ConvNet where the instances of the data acquired were five features:

- Brightness,
- Variation in X, Y and Z axis,
- Force sensitive resistor,
- Temperature, humidity, pressure,
- Air quality.

See Figure 7 for the results of the valuation that were restructured for this article, which show the different sensors that were analysed for the possible situations in which the worker was subjected to certain conditions. Table 3 shows different possible circumstances ranging from having an environment conducive to work (such as good air quality, sufficient lighting) to having structural or physical risk (such as detecting falls through the CNN, lack of lighting, environment compromised by harmful gases). In the present work, the objective was to reduce reaction times in the event of an accident or mishap. For the smart helmet developed in our previous research, in which 12 different classes of events were classified for prompt action by personnel in charge of ensuring the safety of workers in industrial areas, the final performance of the CNN was 92.05% on average for all classes (represented with different colours). Cross-validation resulted in 20% for the CNN for the smart helmet.

3.2. Smart Bracelet with Platform

The smart bracelet is a device designed to be worn on the operator's hand [43]. The inputs of the model are the body temperature of the user, their heart rate and a variable that indicates the status of the bracelet; that is to say, the optimal condition that is given by the battery or physical coupling. A label among four situations in a real working environment can be expected, such as a heart attack alert through agitation or falls, etc.

Problems recorded in the environment

- Heart attack and irregular heartbeat,
- Extreme temperature changes leading to a heat stroke,
- Unhealthy temperature for the worker,

- Slips, trips and falls,
- Blows to the worker's hand,
- Reporting an accident,

Table 3. Table showing the restructured labels of the work focused on the intelligent case, one of the three components used to model them through complex networks.

Label	Meaning in the Model
0	Good for health air (AQI from 0 to 50) with sufficient illumination in the working environment.
1	Moderate air quality (AQI of 51 to 100) with slight variation in temperature and humidity.
2	Harmful air to health for sensitive groups (AQI 101–150) with moderate variation in temperature and humidity.
3	Harmful air to health (AQI 151 to 200) with considerable variation in temperature and humidity
4	Very harmful air to health (AQI 201 to 300) with high variation in temperature and humidity.
5	Hazardous air (AQI greater than 300) with atypical variation in temperature and humidity.
6	Lack of illumination and variation equivalent to a fall in axes.
7	Lack of illumination and variation equivalent to a fall in axes and considerable force exerted on the helmet.
8	Atypical variation on the detected axes and moderate force detected on the FSR.
9	Illumination problems, air quality and sudden variation in axes.
10	Very high force exerted on the FSR.
11	Variation in axes with illumination problems.
12	Outliers on the 5 sensors

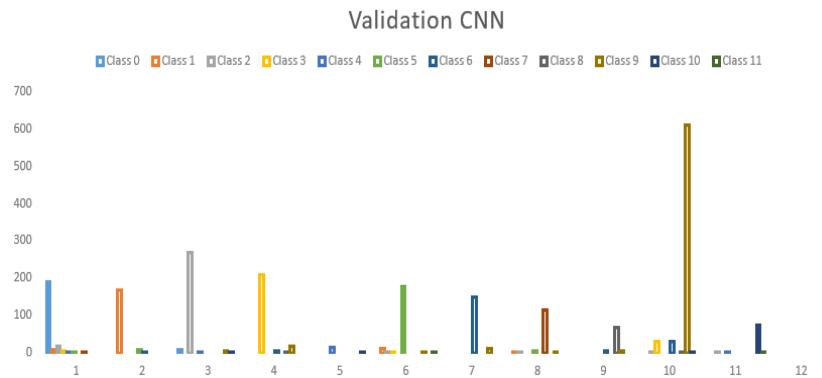


Figure 7. Smart helmet developed in our previous research [43].

The bracelet uses two models. The first is the Gaussian mixture models focused solely on the analysis of the vital signs of the worker or user, as well as the status of the bracelet. The second model is the LSTM neural network, used to analyse the human activity behaviour, see Figure 8 where it shows the classification results of a GMM for four different classes, with an average performance in real-time of 78.75%, and Figure 9 where the results obtained for the GMM and LSTM are shown, respectively. The confusion matrix LSTM indicates the other model selected for the developed bracelet as GMM did not have a sufficient level of generalisation by itself. It can be seen that the best class performance was 96.14% for the WalkingScaling class, 89.2% for Falls and 77.06% for Carrying, which is the most difficult class to predict in our dataset.

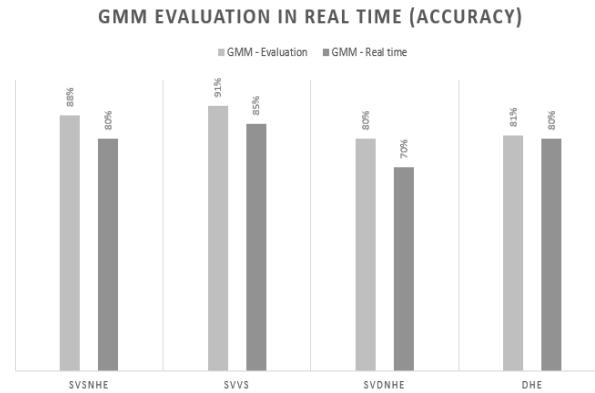


Figure 8. Results of GMM in real-time, where the definition of the labels are: worker with stable vital signs and non-hostile environment, which we will define as SVSNHE, worker with smooth variation in vital signs, SVVS, worker with vital signs in dangerous and non-hostile environments, defined here as SVDNHE, and worker in danger due to hostile environment, DHE. Bracelet developed for human behavioural analysis.

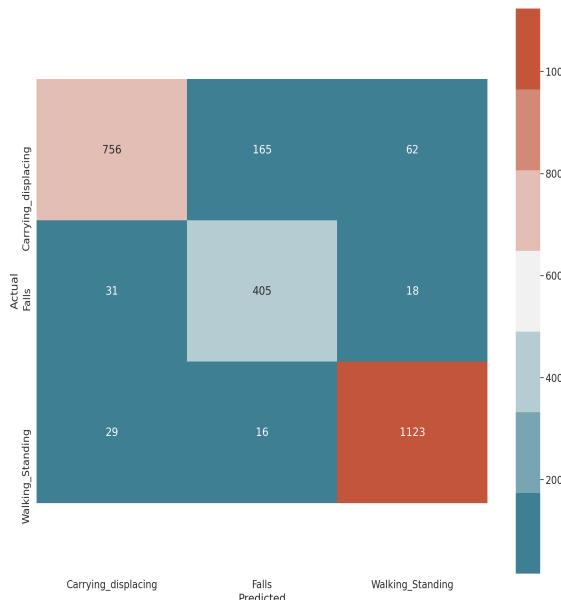


Figure 9. Confusion matrix LSTM.

3.3. Smart Belt Design by Naive Bayes Classifier

The purpose of the belt is [42] very similar to the two previous ones; however, in each device, there is a variation from the perspective of the accelerometers due to the position of the body where they are located, which is why no information is discarded because it is a complement. For the belt, the following labels were obtained, where it is worth mentioning that each device was subjected to a Fisher statistical analysis to verify the non-overlapping of classes.

Problems recorded in the environment and its label

- Low Battery 1,

- Z-axis difference greater than low value 2,
- Z-axis difference greater than average value 3,
- Z-axis difference greater than high value 4,
- High decibels 5,
- Panic button on 6,
- Low battery and difference on Z axis greater than low value 7,
- Low battery and difference on Z axis greater than average value 8,
- Low battery and difference on Z axis greater than high value 9,
- Low battery and high decibels 10,
- Low battery panic button activated 11,
- Difference on Z axis greater than low value and high decibels 12,
- Z-axis difference greater than mean value and high decibels 13,
- Z-axis difference greater than high value and high decibels 14,
- Z-axis difference greater than low value and emergency button activated 15,
- Z-axis difference greater than mean value and emergency button activated 16,
- Z-axis difference greater than high value and emergency button activated 17,
- Panic button activated and high decibels 18,
- Z-axis difference greater than low value and high decibels and low battery 19,
- Z-axis difference greater than mean value and high decibels and low battery 20,
- Z-axis difference greater than high value and high decibels and low battery 21.

3.4. Integration

To integrate all the information, it is important to recapitulate that the smart helmet has 12 possible labels, the bracelet has a total of 7 distributed in 2 different models, the GMM and the LSTM, and finally the belt has 12. Our work proposes to see each of the different outputs as nodes in a network, where information modelling has significantly better results than in traditional models.

That is why our approach is based on not only analysing the 40 possible labels but also being prepared for possible contingencies where one of the devices is inactive or it is necessary to reduce the noise/risk of prediction/classification, for which we propose the use of heuristics and machine learning to filter the final information in the proposed network, see Figure 10. This diagram represents how the labels (final output) of each model are used together to create a graph that allows us to have each label represented as a node. The reader may have noticed that we are talking about model ensembles with the difference that our boosting is given by an independent dataset on each model. Our ultimate goal is to integrate everything into a decision making process that in turn generalises a vote.

The graph created with the different labels can be seen in Figure 11. This image represents the relationship that exists between the labels when analysing the three devices in parallel; as mentioned, we want to reduce the risk of misclassification by finding the relationship between the output labels of each model, i.e., the input of the analysis by heuristics is the output of the models of the electronic devices. For the network generated with the different outputs of the four integrated models, each colour represents belonging to a certain model, for example, the 3 orange nodes represent the output of the LSTM (3 classes), the 4 blue nodes the 4 of the GMM, the 12 green nodes to the CNN and the rest to the Naive Bayes. This is how to achieve the joint responses of all the models.

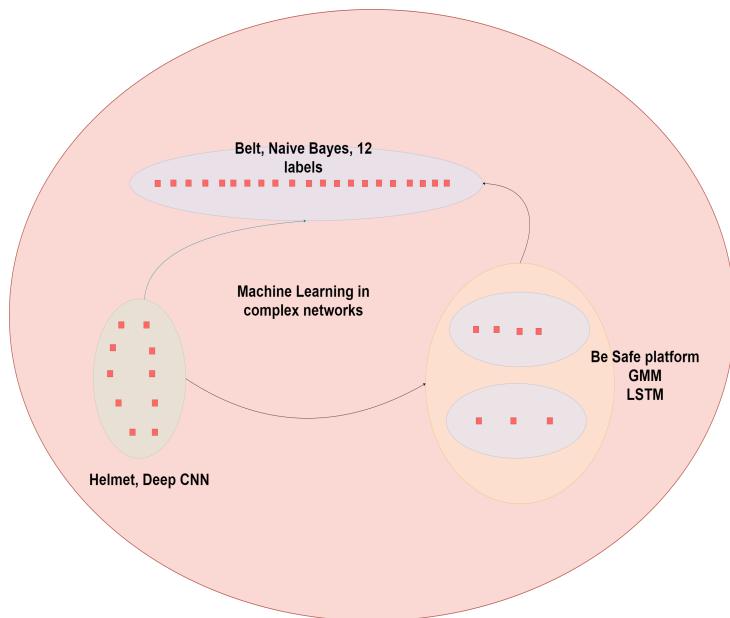


Figure 10. Final interpretation of devices through heuristics and machine learning applied to complex networks.

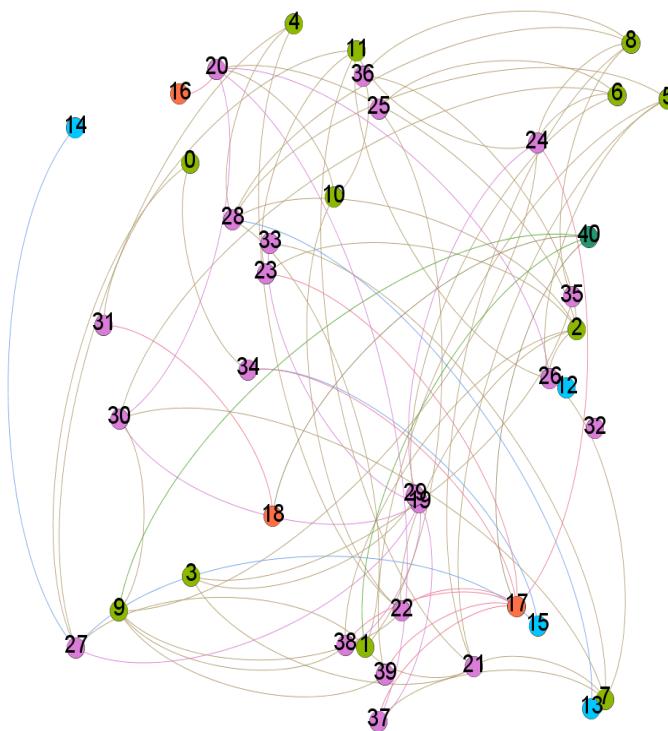


Figure 11. Image obtained by plotting the network in the Gephi software.

Procedure

Machine learning (ML) is the study of computer algorithms that improve automatically through experience. This means that it is possible to make predictions or approximations on the basis of information with similar characteristics. In ML, we have two big categories, unsupervised and supervised learning. In the current project, we work with supervised learning, which is a technique for deducing a function from training data. Training data consists of pairs of objects (usually vectors): one component of the pair is the input data and the other is the desired results. For that we need to create a training dataset.

By creating a dataset for validation, we choose an unknown part of the multisensory network for the model in order to evaluate its performance. Regularly, in ML, we train the models with features that represent the nature of the data, but what kind of information can be used in graphs? One option is heuristics. Heuristics allow designing a score based on network topology.

- The Adamic–Adar index is a measure introduced in 2003 by Lada Adamic and Eytan Adar to predict links in a social network. The Adamic–Adar of a pair of nodes (u) and (v) is defined as in Equation (1):

$$\sum_{w \in \Gamma(u) \cap \Gamma(v)} \frac{1}{\log |\Gamma(w)|} \quad (1)$$

where $(\Gamma(u))$ denotes the set of neighbours of (u). That is why w is the intersection neighbours between both nodes.

Another heuristic is the Jaccard coefficient, which measures the similarity between finite sample sets, and is defined as the size of the intersection divided by the size of the union of the sample sets. The Jaccard coefficient of nodes (u) and (v) is defined as in Equation (2), where $|$ means the absolute value:

$$\frac{|\Gamma(u) \cap \Gamma(v)|}{|\Gamma(u) \cup \Gamma(v)|} \quad (2)$$

where $(\Gamma(u))$ denotes the set of neighbours of (u).

Given a fixed network, is it possible to predict how the label network is going to look in the future? The Soundarajan–Hopcroft index indicates the count of common neighbours between two nodes, summed together with the count of common neighbours that belong to the same community as the two nodes. For two nodes (u) and (v), this function computes the number of common neighbours and a bonus one for each common neighbour belonging to the same community as (u) and (v). Mathematically, Equation (3):

$$\sum_{w \in \Gamma(u) \cap \Gamma(v)} \frac{f(w)}{|\Gamma(w)|} \quad (3)$$

where $(f(w))$ equals 1 if (w) belongs to the same community as (u) and (v) or 0 otherwise, and $(\Gamma(u))$ denotes the set of neighbours of (u).

The dependent variables (outputs) for the datasets will be created since they will indicate whether or not there is a relationship between each set of output labels. The heuristics have a very close approximation to the real relationships, which can be verified through the evaluation of the real data against the data obtained by each heuristic.

Once we have the heuristics we can use them as features to train our model and then use that information to try to predict links between the new network when the set of devices is used in real-time. X represents the input and can be provided as a list: each of the internal lists corresponds to the features of one node pair. y is the list of values to predict. X will be prepared by combining the heuristics that have been used.

Two common steps are involved in machine learning algorithms to learn how to combine heuristics for optimising predictions:

- Training: show features + value to predict;

- Using/Validating: try to predict value from features.

The general process is described in [40], where our objective is to find the relationship between the tags of the 3 devices and send a tag number 41, which allows us to validate the correct operation of the entire security platform. In summary, what is done is the following (example directed to link prediction):

- Starting from a graph, we choose a set of heuristics available in the stat-of-the-art for complex networks (the most common ones are: Jaccard coefficient, Hub Promoted, Adamic Adar, etc.).
- Referring to the Jaccard Coefficient, this allows us to establish a coefficient for a specific node (defined as similarity based on the neighbourhood of the node), this value will become a characteristic for the input vector that will be used for the final modelling.
- The process is repeated by assigning a value by a heuristic to each node pair combination in the network, where at the end we will have an input vector for each node pair with a target that is identified with 0 or 1, depending on whether or not there is a link between each node pair.
- Finally, an ML model is applied to the generated data where what we are doing is weighting the response of the different artificial intelligence models represented as a complex network to reduce the classification noise in industrial and work environments. The entire process is summarised in Figure 12.

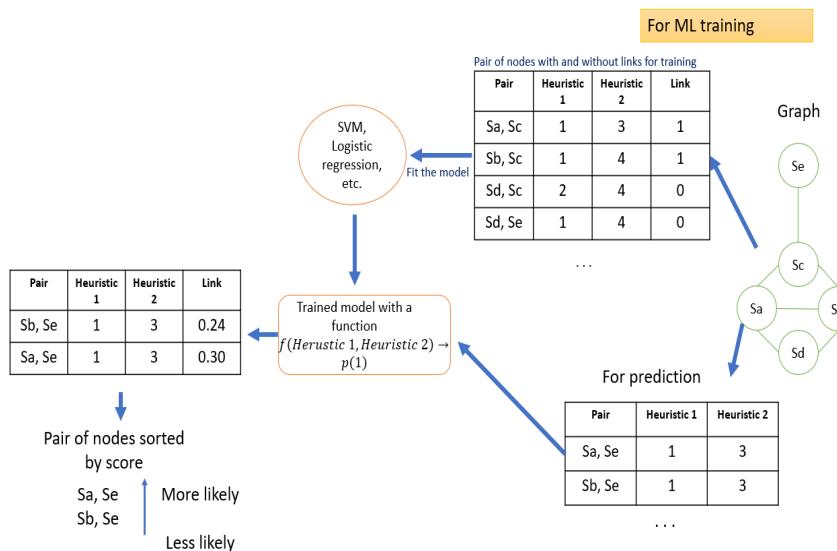


Figure 12. Explanation of the process of including ML for joint decision making over an entire network. The flow of the diagram is from right to left.

Based on the above, we made a comparison between a Gaussian Naive Bayes, random forest, support vector machine (SVM) and a linear regression, where the result is quite favourable, see Figure 13. This allows us to see that there is a strong relationship when any of the labels warn the user of a danger in their environment or they are alerted of their vital signs, which likewise, allows the integration of the three devices that have been developed.

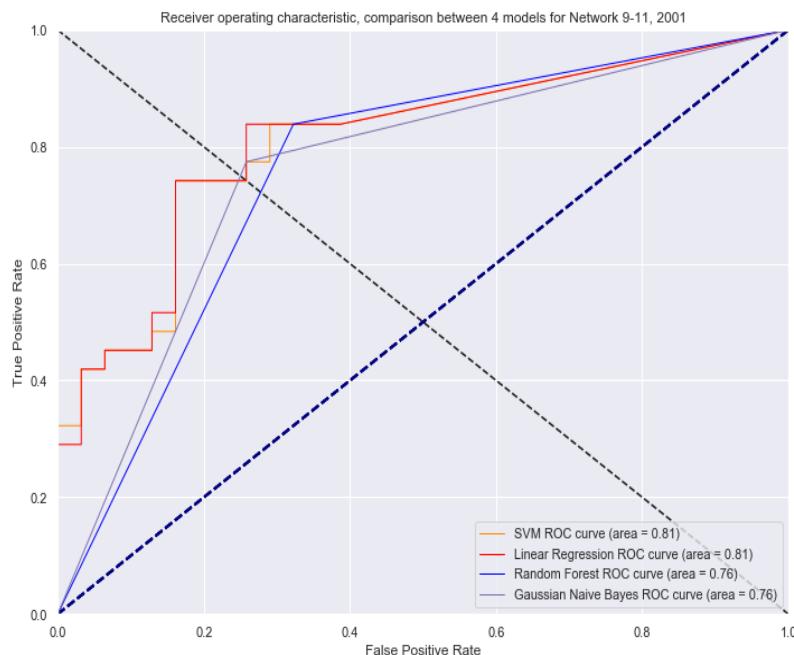


Figure 13. Receiver operating characteristic (ROC) curves in the analysis of different models for the integration of the complete multiplatform.

Here, the entire process is summarised. We have four models integrated into three different devices. There is an analogy in the field of artificial intelligence that a single model is not as good as several models together looking for something specific (analogy of the elephant and the blind men). That is why we decided to include a decision-making process for different wearables to get a picture of what is really going on. Several of these models have independent variables in common but are not linearly related. This allows us to make a decision based on votes as an AdaBoost model, where our Boosting comes from the independence of each dataset. The complex network allows all outputs to be represented as nodes for easy analysis and once this is done we can now use heuristics to determine if a situation is actually happening or not.

4. Discussion and Conclusions

The increasing presence of new technologies in the workplace has become more than evident in the last two decades, revolutionising work environments and increasing productivity. In the near future, we will witness an increase in the application of these technologies to ensure the well-being and health of employees, adapting the form of smart PPE and becoming more accessible to the public once their application and use become popular. The popularisation of smart PPE will be crucial in metallurgy, mining, fishing, commercial and construction due to their high-risk rate and high lethality. The development of smart PPE will be driven in tandem by advancing artificial intelligence, which will enable systems to become more adaptive and intelligent and meet the widespread demand for safer workplaces.

The implementation of IoT and wearable technology has revolutionised the field of smart PPE. Workers are individually monitored by the sensors implemented in wearables. The information can be sent to a central node that monitors and provides personalised responses to different individuals on the basis of the data received from them. These benefits have already been recognised by different industries experimenting with these technolo-

gies and their applications in their work environments. The platforms that companies currently have in place focus on production and productivity aspects. One component to reduce these causes is the implementation of protective measures, especially where it is not possible to determine standards to ensure the integrity of the individual. As a result, it is important to use PPE, such as belts, helmets and other devices that protect the physical integrity of the operator. Furthermore, with the use of edge computing, we can implement this solution in areas with a lack of connectivity and relatively cheaply with the consequent impact on reducing casualties or accidents in any country.

Legal requirements force companies to make significant investments in protective equipment, an area in which they strive to stand out from among their competitors and to comply with regulations at a reasonable cost. For this reason, the use of technologies such as IoT, Big Data and Cloud Computing in protective equipment is of high interest to companies. The BeSafe 2.0 platform implements next-generation technologies in these fields (AIoT, smart data, advanced machine learning, predictive algorithms and advanced support decision systems).

An important goal for the future is to patent or register the hardware, algorithms, and derived services etc., as intellectual property, so that the investment that is being made is safeguarded and the technology can be extrapolated to other potential markets, exploiting the results through multiple business models.

Finally, it is necessary to continue developing new proposals and protective equipment for different areas of application, adapting the technology to meet their security needs. Workplace accidents are a very important problem for worker's care due to various factors that represent a risk to them.

Likewise, by implementing artificial intelligence techniques in the hardware, it is possible to improve the predictive capacity of the electronic system, placing it as an essential step for the improvement of equipment by implementing emerging technologies in the hardware of the PPE. In addition, the implementation of 5G technology has been contemplated, which has the great advantage of supporting a higher bandwidth, which will translate into higher download speeds [23].

Author Contributions: Conceptualization and methodology S.M.-S.; Data Curation I.C.-J.; and J.H.-S.; writing-original draft preparation S.M.-S. and I.C.-J.; data curation I.C.-J.; validation S.R.; and J.M.C.; writing, review and editing S.R.; and S.M.-S.; All authors have read and agreed to published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Informed consent was obtained from all subjects involved in the study.

Data Availability Statement: Not applicable.

Acknowledgments: This research was partially supported by the project "Computación cuántica, virtualización de red, edge computing y registro distribuido para la inteligencia artificial del futuro", Reference: CCTT3/20/SA/0001, financed by Institute for Business Competitiveness of Castilla y León, and the European Regional Development Fund (FEDER).

Conflicts of Interest: The authors declare no conflict of interest.

References

- Shahnavaz, H. Workplace injuries in the developing countries. *Ergonomics* **1987**, *30*, 397–404. [[CrossRef](#)] [[PubMed](#)]
- Friend, M.A.; Kohn, J.P. *Fundamentals of Occupational Safety and Health*; Rowman & Littlefield: Lanham, MD, USA, 2018.
- Smitha, M.W.; Kirk, K.A.; Oestenstad, K.R.; Brown, K.C.; Lee, S.-D. Effect of state workplace safety laws on occupational injury rates. *J. Occup. Environ. Med.* **2001**, *43*, 1001–1010. [[CrossRef](#)]
- Boden, L.I.; Ruser, J.W. Workers' compensation "reforms," choice of medical care provider, and reported workplace injuries. *Rev. Econ. Stat.* **2003**, *85*, 923–929. [[CrossRef](#)]
- Bonato, P. Wearable sensors and systems. *IEEE Eng. Med. Biol. Mag.* **2010**, *29*, 25–36. [[CrossRef](#)] [[PubMed](#)]

6. Park, S.; Jayaraman, S. Enhancing the quality of life through wearable technology. *IEEE Eng. Med. Biol. Mag.* **2003**, *22*, 41–48. [[CrossRef](#)] [[PubMed](#)]
7. Miorandi, D.; Sicari, S.; De Pellegrini, F.; Chlamtac, I. Internet of things: Vision, applications and research challenges. *Ad Hoc Netw.* **2012**, *10*, 1497–1516. [[CrossRef](#)]
8. Campero-Jurado, I.; Márquez-Sánchez, S.; Quintanar-Gómez, J.; Rodríguez, S.; Corchado, J.M. Smart Helmet 5.0 for industrial internet of things using artificial intelligence. *Sensors* **2020**, *20*, 6241. [[CrossRef](#)]
9. Sánchez, S.M.; Vara, R.C.; Criado, F.J.G.; González, S.R.; Tejedor, J.P.; Corchado, J.M. Smart PPE and CPE Platform for Electric Industry Workforce. In *International Workshop on Soft Computing Models in Industrial and Environmental Applications*; Springer: Cham, Switzerland, 2019.
10. Sánchez, M.; Rodriguez, C.; Manuel, J. Smart Protective Protection Equipment for an accessible work environment and occupational hazard prevention. In Proceedings of the 2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence), Noida, India, 29–31 January 2020.
11. Sánchez, S.M. Electronic Textiles for Intelligent Prevention of Occupational Hazards. In *International Symposium on Distributed Computing and Artificial Intelligence*; Springer: Cham, Switzerland, 2019.
12. Podgorski, D.; Majchrzycka, K.; Dąbrowska, A.; Gralewicz, G.; Okrasa, M. Towards a conceptual framework of OSH risk management in smart working environments based on smart PPE, ambient intelligence and the Internet of Things technologies. *Int. J. Occup. Saf. Ergon.* **2017**, *23*, 1–20. [[CrossRef](#)]
13. Chae, H.S.; Ko, M.S.; Kim, H.C.; Kim, K.S.; Choi, D.P.; Kim, K.R.; Lee, K.S. Development Trends of Smart Personal Protective Equipment for Agricultural Health and Safety. *J. Ergon. Soc. Korea* **2017**, *36*, 677–691.
14. Tulshyan, V.; Sharma, D.; Mittal, M. An Eye on the Future of COVID'19: Prediction of Likely Positive Cases and Fatality in India over A 30 Days Horizon using Prophet Model. *Disaster Med. Public Health Prep.* **2020**, *1*, 1–20. [[CrossRef](#)]
15. Islam, A. Use of PPE in Response of Coronavirus (COVID-19): A Smart Solution to Global Economic Challenges? Ph.D. Thesis, Putra Business School, Seri Kembangan, Malaysi .
16. Rajendran, S.D.; Wahab, S.N.; Yeap, S.P. Design of a smart safety vest incorporated with metal detector kits for enhanced personal protection. *Saf. Health Work.* **2020**, *11*, 537–542. [[CrossRef](#)]
17. Fischer, W.A., II; Weber, D.J.; Wohl, D.A. Personal protective equipment: Protecting health care providers in an Ebola outbreak. *Clin. Ther.* **2015**, *37*, 2402–2410. [[CrossRef](#)] [[PubMed](#)]
18. Gazafroudi, A.S.; Soares, J.; Ghazvinic, M.A.F.; Pinto, T.; Vale, Z.; Corchado, J.M. Stochastic interval-based optimal offering model for residential energy management systems by household owners. *Int. J. Electr. Power Energy Syst.* **2019**, *105*, 201–219. [[CrossRef](#)]
19. Román, J.A.; Rodríguez, S.; de la Prieta, F. Improving the distribution of services in MAS. In *International Conference on Practical Applications of Agents and Multi-Agent Systems*; Springer: Cham, Switzerland, 2016.
20. Chamoso, P.; De La Prieta, F.; Eibenstein, A.; Santos-Santos, D.; Tizio, A.; Vittorini, P. A device supporting the self management of tinnitus. In *International Conference on Bioinformatics and Biomedical Engineering*; Springer: Cham, Switzerland, 2017.
21. Sittón, I.; Rodríguez, S. Pattern extraction for the design of predictive models in industry 4.0. In *International Conference on Practical Applications of Agents and Multi-Agent Systems*; Springer: Cham, Switzerland, 2017.
22. Sánchez, S.M.; Lecumberri, F.; Satí, V.; Arora, A.; Shoeibi, N.; Rodríguez, S.; Rodríguez, J.M.C. Edge Computing Driven Smart Personal Protective System Deployed on NVIDIA Jetson and Integrated with ROS. In *International Conference on Practical Applications of Agents and Multi-Agent Systems*; Springer: Cham, Switzerland, 2020.
23. Sun, X.; Ansari, N. Edgelot: Mobile edge computing for the Internet of Things. *IEEE Commun. Mag.* **2016**, *54*, 22–29. [[CrossRef](#)]
24. Heras, S.; De la Prieta, F.; Julian, V.; Rodríguez, S.; Botti, V.; Bajo, J.; Corchado, J.M. Agreement technologies and their use in cloud computing environments. *Prog. Artif. Intell.* **2012**, *1*, 277–290. [[CrossRef](#)]
25. Shawish, A.; Salama, M. Cloud computing: Paradigms and technologies. In *Inter-Cooperative Collective Intelligence: Techniques and Applications*; Springer: Berlin/Heidelberg, Germany, 2014; pp. 39–67.
26. Shi, W.; Cao, J.; Zhang, Q.; Li, Y.; Xu, L. Edge computing: Vision and challenges. *IEEE Internet Things J.* **2016**, *3*, 637–646. [[CrossRef](#)]
27. Shi, W.; Dustdar, S. The promise of edge computing. *Computer* **2016**, *49*, 78–81. [[CrossRef](#)]
28. Satyanarayanan, M. The emergence of edge computing. *Computer* **2017**, *50*, 30–39. [[CrossRef](#)]
29. Boyes, H.; Hallaq, B.; Cunningham, J.; Watson, T. The industrial internet of things (IIoT): An analysis framework. *Comput. Ind.* **2018**, *101*, 1–12. [[CrossRef](#)]
30. Mobley, R.K. *An Introduction to Predictive Maintenance*; Elsevier: Amsterdam, The Netherlands, 2002.
31. Chamoso, P.; González-Briones, A.; Rivas, A.; De La Prieta, F.; Corchado, J.M. Social computing in currency exchange. *Knowl. Inf. Syst.* **2019**, *61*, 733–753. [[CrossRef](#)]
32. Puig Ramírez, J. Asset Optimization and Predictive Maintenance in Discrete Manufacturing Industry. Master's Thesis, École Polytechnique Fédérale de Lausanne, Lausanne, Switzerlan , 2010.
33. Chamoso, P.; De Paz, J.F.; Bajo, J.; Villarrubia, G. Intelligent control of energy distribution networks. In *International Conference on Practical Applications of Agents and Multi-Agent Systems*; Springer: Cham, Switzerland, 2016.
34. Van Den Oord, A.; Dieleman, S.; Schrauwen, B. Deep content-based music recommendation. In *Neural Information Processing Systems Conference (NIPS 2013)*; Neural Information Processing Systems Foundation (NIPS): Lake Tahoe, NV, USA, 2013; Volume 26.

35. Chen, Z.-Y.; Kuo, R.J. Evolutionary algorithm-based radial basis function neural network training for industrial personal computer sales forecasting. *Comput. Intell.* **2017**, *33*, 56–76. [[CrossRef](#)]
36. Yegnanarayana, B. *Artificial Neural Networks*; PHI Learning Pvt. Ltd.: Delhi, India, 2009.
37. Leake, D.B. *Case-Based Reasoning: Experiences, Lessons, and Future Directions*; MIT Press: Cambridge, MA, USA, 1996.
38. Goodfellow, I.; Bengio, Y.; Courville, A. *Deep Learning*; MIT Press: Cambridge, MA, USA, 2016; Volume 1, No. 2.
39. Riverola, F.F.; Corchado, J.M. Sistemas híbridos neuro-simbólicos: Una revisión. *Intel. Artif. Rev. Iberoam. Intel. Artif.* **2000**, *4*, 12–26.
40. Silva, T.C.; Zhao, L. *Machine Learning in Complex Networks*; Springer International Publishing: Cham, Switzerland, 2016; Volume 1.
41. Stephenson, M.; Amarasinghe, S.; Martin, M.; O'Reilly, U.M. Meta optimization: Improving compiler heuristics with machine learning. *ACM Sigplan Not.* **2003**, *38*, 77–90. [[CrossRef](#)]
42. Márquez-Sánchez, S.; Campero-Jurado, I.; Quintanar-Gómez, J.; Rodríguez, S.; Corchado, J.M. Smart Belt Design by Naive Bayes Classifier for Standard Industrial Protection Equipment Integration. *Int. J. Artif. Intell.* **2020**, *18*, 186–201.
43. Márquez-Sánchez, S.; Campero-Jurado, I.; Robles-Camarillo, D.; Rodríguez, S.; Corchado-Rodríguez, J.M. BeSafe B2.0 Smart Multisensory Platform for Safety in Workplaces. *Sensors* **2021**, *21*, 3372. [[CrossRef](#)] [[PubMed](#)]

Capítulo 5

Evidencias y Resultados



VNiVERSiDAD
D SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

Evidencias y Resultados

En este Capítulo se presenta el conjunto de publicaciones en revistas científicas y congresos internacionales en los cuales se ha contribuido, reflejando el desarrollo y los resultados de las diferentes líneas de investigación que han culminado en esta Tesis Doctoral. En este sentido, la estructura de este Capítulo es la siguiente. La Sección 5.1 detalla las publicaciones realizadas en revistas científicas, conferencias y workshops internacionales, expuestas en orden cronológico inverso. La Sección 5.2 enumera los proyectos en los que se ha participado y que han sustentado las diferentes líneas de investigación desarrolladas que han llevado a esta Tesis Doctoral. Por último, la Sección 5.3 describe las estancias llevadas a cabo en organismos de investigación internacionales relacionadas con las líneas de investigación de esta Tesis Doctoral.

5.1. Publicaciones

En primer lugar, se detallan las diferentes publicaciones llevadas a cabo en revistas científicas internacionales, Capítulos de libro, así como congresos internacionales y workshops, relacionadas con las líneas de investigación que han llevado a la elaboración de esta Tesis Doctoral. En cada bloque, se presentan las entradas en orden cronológico inverso según la fecha de publicación. En el caso de las revistas científicas internacionales, se señalan en **negrita** aquéllas que forman parte de la Tesis Doctoral como compendio de artículos/publicaciones. Asimismo, se refleja en **azul** el factor de impacto y el cuartil al que pertenece cada revista internacional según el año de publicación o, en su defecto el último factor de impacto disponible antes de la publicación del artículo o, en caso de que la revista no contara aún con factor de impacto en la fecha de publicación, el factor de impacto del primer año calculado para la revista tras la publicación del artículo.

5.1.1. Publicaciones en revistas científicas internacionales

1. Márquez-Sánchez, S., Campero-Jurado, I., Herrera-Santos, J., Rodríguez, S., & Corchado, J. M. (2021). Intelligent Platform Based on Smart PPE for Safety in Workplaces. *Sensors*, 21(14), 4652. [\[JCR 3.576 - \(2021\)\]](#).
2. Campero-Jurado, I., Márquez-Sánchez, S., Quintanar-Gómez, J., Rodríguez, S., & Corchado, J. M. (2020). Smart Helmet 5.0 for industrial internet of things using artificial intelligence. *Sensors*, 20(21), 6241. [\[JCR 3.576 - Q1 Instrument and Instrumentation Q2 Engeniering \(2021\)\]](#).
3. Campero-Jurado, I., Márquez-Sánchez, S., Quintanar-Gómez, J., Rodríguez, S., & Corchado, J. M. (2020). Smart Helmet 5.0 for industrial internet of things using artificial intelligence. *Sensors*, 20(21), 6241. [\[JCR 3.576 - \(2020\)\]](#).
4. Junior, R. M. G., Márquez-Sánchez, S., Santos, J. H., de Almeida, R. M. A., London Junior, J. B. A., & Rodríguez, J. M. C. (2022). Validation of Embedded State Estimator Modules for Decentralized Monitoring of Power Distribution Systems Using IoT Components. *Sensors*, 22(6), 2104. [\[JCR 3.576 - \(2022\)\]](#).
5. Sánchez, S. M. (2020). Integral Support Predictive Platform for Industry 4.0. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 9(4), 71-82.
6. Rodríguez, S., & Corchado, J. M. (2020). Smart Belt Design by Naïve Bayes Classifier for Standard Industrial Protection Equipment Integration. *Int. J. Artif. Intell.*, 18, 186-201.
7. Parra-Domínguez, J., Herrera Santos, J., Márquez-Sánchez, S., González-Briones, A., & De la Prieta, F. (2021). Technological Developments of Mobility in Smart Cities. An Economic Approach. *Smart Cities*, 4(3), 971-978.
8. Sánchez, S. M., Mora-Simon, S., Herrera-Santos, J., Roncero, A. O., & Corchado, J. M. (2020). Intelligent Dolls and robots for the treatment of elderly people with

- dementia. ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal, 9(1), 99-112.
9. Sánchez, S. M. (2019, June). Electronic Textiles for Intelligent Prevention of Occupational Hazards. In International Symposium on Distributed Computing and Artificial Intelligence (pp. 217-220). Springer, Cham.
 10. Marquez, S., Casado-Vara, R., González-Briones, A., Prieto, J., & Corchado, J. M. (2018, June). SiloMAS: A MAS for Smart Silos to Optimize Food and Water Consumption on Livestock Holdings. In International Symposium on Distributed Computing and Artificial Intelligence (pp. 27-37). Springer, Cham.
 11. González-Briones, A., Casado-Vara, R., Márquez, S., Prieto, J., & Corchado, J. M. (2018, June). Intelligent Livestock Feeding System by Means of Silos with IoT Technology. In International Symposium on Distributed Computing and Artificial Intelligence (pp. 38-48). Springer, Cham.

5.1.2. Publicaciones en congresos internacionales y workshops

1. González, A. B. G., Márquez, S., García, M. R., Corchado, J. M., & Luis-Reboredo, A. (2021). Hacia un Dispositivo Wearable Electrónico Inteligente de Corrección Postural Asociado a la Espalda. Revista de la Asociación Interacción Persona Ordenador (AIPO), 2(2), 63-73.
2. Márquez-Sánchez, S., Herrera-Santos, J., Campero-Jurado, I., González-Arrieta, A., & Prieta-Pintado, F. D. L. (2021, October). Smart Agriculture System Integrating LoRaWAN and Edge Computing Technologies. In International Symposium on Distributed Computing and Artificial Intelligence (pp. 99-109). Springer, Cham.
3. González, A. B. G., Márquez, S., García, M. R., Corchado, J. M., & Luis-Reboredo, A. (2021). Hacia un Dispositivo Wearable Electrónico Inteligente de Corrección Postural Asociado a la Espalda. Revista de la Asociación Interacción Persona Ordenador (AIPO), 2(2), 63-73.
4. Sánchez, S. M., Lecumberri, F., Sati, V., Arora, A., Shoeibi, N., Rodríguez, S., & Rodríguez, J. M. C. (2020, October). Edge Computing Driven Smart Personal

- Protective System Deployed on NVIDIA Jetson and Integrated with ROS. In International Conference on Practical Applications of Agents and Multi-Agent Systems (pp. 385-393). Springer, Cham.
5. Sati, V., Sánchez, S. M., Shoeibi, N., Arora, A., & Corchado, J. M. (2020, June). Face Detection and Recognition, Face Emotion Recognition Through NVIDIA Jetson Nano. In International Symposium on Ambient Intelligence (pp. 177-185). Springer, Cham.
 6. Sánchez, S. M., Rodriguez, C., & Manuel, J. (2020, January). Smart Protective Protection Equipment for an accessible work environment and occupational hazard prevention. In 2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence) (pp. 581-585). IEEE.
 7. Sánchez, S. M., Vara, R. C., Criado, F. J. G., González, S. R., Tejedor, J. P., & Corchado, J. M. (2019, May). Smart PPE and CPE Platform for Electric Industry Workforce. In International Workshop on Soft Computing Models in Industrial and Environmental Applications (pp. 422-431). Springer, Cham.
 8. Chimeno, S. G., Fernández, J. D., Sánchez, S. M., Ramón, P. P., Ospina, Ó. M. S., Muñoz, M. V., & Hernández, A. G. (2018, June). Domestic Violence Prevention System. In International Symposium on Distributed Computing and Artificial Intelligence (pp. 10-14). Springer, Cham.

5.2. Proyectos

A continuación se listan los diferentes proyectos financiados a nivel europeo, nacional o regional en los que se ha participado como miembro del equipo investigador contratado en el transcurso del desarrollo de las investigaciones que han conducido a esta Tesis Doctoral, en orden cronológico inverso. Para cada uno de ellos, se detalla la entidad o entidades financieras, su localización, la entidad donde tuvo lugar el proyecto y su ubicación, el nombre del programa bajo el paraguas del cual se financió el proyecto, así como las fechas de inicio y fin del mismo.

1. 1. PLATINUM: Plataforma horizontal de Smart Data y Deep Learning para la industria y aplicación al sector manufacturero (RTC-2017-6401-7).

- Entidad/es financiadora/s: FEDER /Ministerio de Ciencia, Innovación y Universidades – Agencia Estatal de Investigación.
- Ciudad/es entidad/es financiadora/s: Bruselas (Unión Europea) y Madrid (España).
- Entidad donde el proyecto tuvo lugar: Universidad de Salamanca.
- Ciudad entidad donde el proyecto tuvo lugar: Salamanca (España).
- Nombre del programa: Retos-Colaboración 2017.
- Fecha de inicio – Fecha de fin: 01/2018 – 06/2020.

2. CHROMOSOME: Change and Analysis of Consumer Behaviour at Smart Homes via Social Machine

- Entidad/es financiadora/s: Salamanca Ciudad de Cultura y Saberes
- Ciudad/es entidad/es financiadora/s: Salamanca (España).
- Entidad donde el proyecto tuvo lugar: Universidad de Salamanca.
- Ciudad entidad donde el proyecto tuvo lugar: Salamanca (España).
- Nombre del programa: Programa de Atracción de Talento
- Fecha de inicio – Fecha de fin: 09/2018 – 08/2021.

3. Grupo Operativo SOTSVAN: ESTRATEGIAS TECNOLÓGICAS PARA LA MEJORA DE LA SOSTENIBILIDAD DEL SECTOR GANADERO DE VACAS NODRIZAS (20190020007279).

- Entidad/es financiadora/s: Fondo Europeo Agrícola de Desarrollo Rural (FEADER). Ministerio de Agricultura, Pesca y Alimentación.
- Ciudad/es entidad/es financiadora/s: Bruselas (Unión Europea) y Madrid (España).
- Entidad donde el proyecto tuvo lugar: Universidad de Salamanca.
- Ciudad entidad donde el proyecto tuvo lugar: Salamanca (España).
- Nombre del programa: Ayudas a la ejecución de proyectos de innovación de interés general por grupos operativos de la Asociación Europea para la innovación en materia de productividad y sostenibilidad agrícolas, dentro del Programa Nacional de Desarrollo Rural 2014-2020.

- Fecha de inicio – Fecha de fin: 08/2019 – 06/2021.

4. CO-APS: Crowdsourced Obtention and Analytics of Data About the Crowding of Public Spaces for the Benefit of Public Transport and Mobility in Cities (20212)

- Entidad/es financiadora/s: EIT KIC Urban Mobility
- Entidad donde el proyecto tuvo lugar: Air Institute
- Ciudad/es entidad/es financiadora/s:
- Ciudad entidad donde el proyecto tuvo lugar: Salamanca (España).
- Nombre del programa: EIT Urban Mobility COVID-19 Crisis Response.
- Fecha de inicio – Fecha de fin: 01/07/20 - 31/12/20

5. LOYALTOUR: Intelligent learning tourism platform for activity recommendation and customer loyalty (RTC2019- 007400-7)

- Entidad/es financiadora/s: Ministerio de Ciencia e Innovación
- Entidad donde el proyecto tuvo lugar: Air Institute
- Ciudad/es entidad/es financiadora/s: Madrid (España).
- Ciudad entidad donde el proyecto tuvo lugar: Salamanca (España).
- Nombre del programa: Retos-Colaboración 2019.
- Fecha de inicio – Fecha de fin: 01/09/20 - 31/12/22

6. LAPASSION: Latin-America Practices and Soft Skills for an Innovation Oriented Network

- Entidad/es financiadora/s: Comisión Europea
- Entidad donde el proyecto tuvo lugar: Pelotas (Brasil).
- Ciudad/es entidad/es financiadora/s: Bruselas (Unión Europea).
- Ciudad entidad donde el proyecto tuvo lugar: Pelotas (Brasil).
- Nombre del programa: Erasmus+: Higher Education - International Capacity Building
- Fecha de inicio – Fecha de fin: 10/17 – 10/20

5.3. Estancias internacionales

A continuación se detalla la estancia internacional llevada a cabo fuera de España en la institución de enseñanza superior de prestigio, realizando trabajos de investigación relacionados con esta Tesis Doctoral.

1. Intelligent Systems Lab (ISLAB) Universidade do Minho.
 - Ciudad de la entidad: Braga, 4710 – 057, Portugal
 - Fecha de inicio – Fecha de fin: 11/01/2021 – 30/04/2021

Como resultado de dicha estancia se ha trabajado estrechamente en áreas relacionadas con la Inteligencia Ambiental, Ambient Assisted Living, Entornos Inteligentes, Interfaces Adaptadas y con la incorporación de métodos y técnicas de IA en estos campos. Dentro de los objetivos cumplidos dentro de la estancia, se profundizó en la investigación y análisis del estado de la técnica en entornos inteligentes, además de intercambiar experiencias de uso de estas tecnologías con el profesorado de la Universidad. Durante la estancia se ha podido completar los conocimientos en los últimos avances referentes a la mejora de la seguridad en entornos industriales con el uso de EPIs inteligentes, así como, la generación de dispositivos que repercutan en la mejora del bienestar de los trabajadores.

Capítulo 6

Conclusiones y Trabajo Futuro



VNiVERSiDAD
DE SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

Conclusiones y Trabajo Futuro

En esta Tesis Doctoral se ha presentado una Plataforma Edge-AIoT como medio eficaz que permita incidir en varios aspectos fundamentales para la mejora de los niveles de seguridad y salud en el puesto de trabajo. Las publicaciones presentadas en esta memoria por compendio de artículos, tienen por objetivo presentar la funcionalidad de la solución propuesta. La plataforma está conformada por tres capas fundamentales, cuyas características permiten la realización de un soporte y apoyo del trabajador en tiempo real, mejorando las condiciones de seguridad actuales. Su diseño, permite conocer la realidad del contexto, pudiendo realizar alerta temprana de anomalías, y gracias a sus capacidades de procesamiento y análisis, con los datos recogidos se podrán realizar predicciones, con una mejora significativa de la seguridad en los espacios de trabajo. Este Capítulo presenta la Sección 6.1, con las principales conclusiones que se han obtenido durante la realización de la Tesis Doctoral. Finalmente, las líneas futuras de investigación que han surgido durante el proceso de desarrollo de esta memoria se presentan den la Sección 6.2.

6.1. Conclusiones

La creciente presencia de las nuevas tecnologías en los lugares de trabajo se ha hecho más que evidente en las dos últimas décadas, revolucionando los entornos laborales y aumentando la productividad. En un futuro próximo, asistiremos a un aumento de la aplicación de estas tecnologías con las que garantizar el bienestar y la salud de los empleados, adaptando los EPI y haciéndolos inteligentes, así como accesibles al público, según se extienda su aplicabilidad. La popularización de los EPI inteligentes será crucial en sectores como la metalurgia, la minería, la pesca, el comercio y la construcción, debido

a su alto índice de riesgo y su elevada letalidad. El desarrollo de los EPI inteligentes se verá impulsado en paralelo por el avance de la inteligencia artificial, que posibilita que los sistemas sean más adaptativos y satisfagan la demanda generalizada de lugares de trabajo más seguros.

La implementación del IoT y de la tecnología vestible ha revolucionado el campo de los EPI inteligentes. Los trabajadores son monitoreados individualmente por los sensores implementados en los wearables y posteriormente, la información puede ser enviada a un nodo central que monitoriza y proporciona respuestas personalizadas a los diferentes individuos en base a los datos recibidos de ellos. Estos beneficios ya han sido reconocidos por diferentes industrias que experimentan con estas tecnologías y sus aplicaciones en sus entornos de trabajo. Las plataformas que las empresas tienen actualmente en marcha se centran en aspectos de producción y productividad. Sin embargo, la aplicación de medidas de protección, sobre todo cuando no es posible determinar normas que garanticen la integridad del individuo, es un componente fundamental para reducir estas causas. Por ello, es importante el uso de EPIs inteligentes, como cinturones, cascos y otros dispositivos que protejan la integridad física del operario. Además, con el uso de Edge Computing, podemos integrar esta solución en zonas con falta de conectividad y de forma relativamente barata con el consiguiente impacto en la reducción de víctimas o accidentes en cualquier país.

Para esta Tesis Doctoral se estableció como hipótesis que es posible mejorar la seguridad y salud en el entorno laboral, proporcionando herramientas innovadoras materializadas en forma de equipos de protección individual (o EPIs) con capacidad de responder en tiempo real a los riesgos presentes en los puestos de trabajo en combinación de una plataforma Edge-AIoT, personalizable y adaptable tanto al entorno, como a las circunstancias personales y a las capacidades de cada trabajador.

El planteamiento de esta hipótesis permitió definir el objetivo principal y los específicos, mediante los cuales se ha podido demostrar la hipótesis de partida. En este contexto se ha propuesto como objetivo principal el diseño de una plataforma modular basada en la tecnología Edge Computing, IoT e Inteligencia Artificial, capaz apoyar en tiempo real en el entorno de trabajo y mejorar las condiciones de trabajo en los espacios de trabajo.

La metodología Action-Research o Investigación-Acción, ha sido el marco metodológico con el cual enmarcar el desarrollo de la Tesis Doctoral. Se utilizaron las cinco fases

que permiten conseguir los objetivos establecidos. En primer lugar llevando a cabo una revisión del estado del arte realizando una Systematic Mapping Study o Estudio de Mapeo Sistemático de la Literatura para dar soporte a la investigación, permitiendo identificar otras plataformas similares . En base a esto, se propuso la plataforma capaz de abordar las necesidades y requerimientos asociados al campo de estudio.

Para el análisis inteligente del entorno laboral se han diseñado tres equipos, casco, brazalete y cinturón, que combinados de otros equipos permitan la evaluación y validación de la plataforma. Las conclusiones obtenidas permiten afirmar que se han cumplidos los objetivos definidos (OB1, OB2, OB3, OB4, OB5, OB6, OB7 y OB8) y comprobar la veracidad de la hipótesis. A continuación se detallen estas conclusiones en orden:

(OB1) *Identificar las situaciones de riesgo comunes con los cuales definir las funcionalidades de la plataforma y requisitos que deben incorporarse.*

Dentro de la gran cantidad de información que podemos encontrar en normativas, reglamentos y manuales de prevención de riesgos, se ha llevado a cabo un análisis de todas aquellas recomendaciones que aparecen estos. El objetivo de este estudio fue conocer los riesgos que se pueden detectar gracias a la compatibilidad con las herramientas/dispositivos. Para ello, se han identificado las situaciones que presentan una mayor incidencia en diferentes escenarios, agrupadas por actividad/sector. Gracias a este estudio se ha permitido construir modelos para la detección de riesgos emergentes y crear ontologías para la asociación de acciones y riesgos.

(OB2) *Investigar los factores que permiten caracterizar el nivel de riesgo de una actividad en función del contexto, del trabajador y de los procedimientos que aplica.*

Como parte de las tareas de investigación se ha realizado la especificación de requisitos funcionales con el objeto de identificar las situaciones de riesgo comunes que pueden detectarse con cada uno de los dispositivos que se pretende desarrollar, buscando lograr el mayor impacto posible. En base a esto, se han definido las funcionalidades que han de incorporar los dispositivos, así como los medios técnicos necesarios para su implementación. A partir de la formalización

del modelo, se han creado las reglas de asociación de los riesgos con un conjunto de medidas preventivas dado el contexto de la situación.

- (OB3)** *Investigar en el diseño de nuevas herramientas y soluciones para la monitorización y protección de las personas en su entorno de trabajo, basadas en electrónica wearable y tejidos inteligentes, para su incorporación en EPIs.*

Para una prevención eficaz de las lesiones o de los accidentes mortales en el entorno laboral, la integración de los componentes electrónicos es crucial dada su capacidad de detección precoz de los riesgos, gracias a los sensores y actuadores que incorporan. Parte importante es la transmisión de la información utilizando diferentes protocolos de Internet de las Cosas hacia capas superiores de la plataforma. Por tanto, se ha investigado sobre diferentes Smart EPI y herramientas de nueva generación, basadas en tecnologías innovadoras que finalmente han permitido desarrollar un marco tecnológico propicio para la contextualización de la situación y que favorezcan la prevención de situaciones de riesgo.

- (OB4)** *Investigar y diseñar los equipos y sistemas auxiliares de detección, aviso e identificación de riesgos, que puedan integrarse en los diferentes dispositivos.*

Creación de dispositivos capaz de realizar la monitorización del entorno y detectar elementos o circunstancias perjudiciales para los humanos. Para ello se analizarán todos aquellos parámetros que tienen una incidencia directa con la salud laboral, con el objetivo de generar sistemas que integren sensores que permitan monitorizar de forma efectiva el estado de ubicaciones interiores y exteriores.

- (OB5)** *Investigar sobre técnicas y metodologías sobre el tratamiento de los datos recogidos en los sensores. Uso de análisis de datos, algoritmos de prevención y el uso de la plataforma de control.*

La plataforma propuesta integra datos provenientes de diferentes fuentes que requieren de un desarrollo de conectores que permitan la interconexión de las diferentes capas y la ingesta efectiva de la información recogida, consiguiendo con ello la fusión de la información con el que agregar datos de muy diversa naturaleza. Además, fruto del desarrollo, se han creado un conjunto de herramientas ad-hoc, que permiten hacer estos análisis enfocados a la mejora

de seguridad. De esta forma, se han integrado las mejores metodologías y algoritmos de extracción de conocimiento, a partir de la información disponible, que servirán de base para los sistemas de detección de escenarios y los módulos de predicción y propuesta de soluciones.

- (OB6)** *Integrar las prestaciones que proporciona el AIoT y Smart Data para obtener una plataforma de apoyo en el desempeño de la actividad, capaz de evolucionar y aprender.*

Se han integrado las diferentes capas con la interoperabilidad entre los componentes que conforman la plataforma de forma armonizada. Ello implica la selección e implementación de los conectores y protocolos para la integración entre los diferentes componentes de la plataforma basado en metodologías ágiles. La plataforma enriquece la información que maneja con modelos de tratamiento de datos inteligentes (Smart Data) en tiempo real. Esto ha exigido definir los algoritmos y construir una base de conocimiento sobre la que predecir escenarios y caracterizar situaciones de riesgo, dotando al sistema de la capacidad de comprensión.

- (OB7)** *Diseñar una plataforma modular Edge AIoT escalable, para la ingestión de datos de diferentes dispositivos, que incorpore algoritmos de Inteligencia Artificial para la detección, diagnóstico y el control predictivo de situaciones de riesgo en entornos laborales.*

La plataforma incorpora dos bloques fundamentales de procesamiento (Edge y Cloud Computing), donde entre las acciones desarrolladas se ha diseñado la interconexión entre los bloques para el intercambio de datos, así como las funcionalidades analíticas para dar servicio a las diferentes capas del sistema. Gracias a la funcionalidad de integrar la capacidad de computación al borde, se ha permitido el análisis de los datos de los diferentes dispositivos tanto con conexión a internet como sin ella, así como un mejor funcionamiento de los dispositivos EPIs en las tareas de detección, implicando un aumento significativo de la seguridad, la eficiencia energética y la velocidad de respuesta.

- (OB8)** *Validar el sistema en diferentes entornos de trabajo para el análisis y evaluación del correcto desempeño de los resultados obtenidos.*

Se han realizado una batería de pruebas funcionales para la depuración de errores y corrección y mejora de la plataforma, obteniendo tras ello serie de informes y recomendaciones que permitan proponer una versión funcional mejorada del sistema. Para ello, se han establecido una serie de métricas que han permitido medir los parámetros de rendimiento de cada uno de los componentes, así como de la plataforma de forma global. Realizando finalmente un refinamiento de la plataforma mediante el desarrollo iterativo para conseguir desplegar la versión beta refinada de la plataforma en el Cloud y en el Edge.

6.2. Líneas Futuras de Investigación

Las futuras líneas de investigación se centrarán en la mejora de las limitaciones que se han encontrado, una vez alcanzados los objetivos inicialmente propuesto durante el desarrollo de la Tesis Doctoral. Estas nuevas líneas de investigación, se pueden resumir según se describe a continuación:

- (LI1) *Diseño de nuevos equipos.* En futuras investigaciones se ve necesario seguir diseñando nuevas herramientas y equipos de protección para distintos ámbitos de aplicación, adaptando la tecnología a las necesidades de seguridad, con la búsqueda de generar un beneficio económico para los sectores que empleen la solución.
- (LI2) *Procesamiento de los datos en los dispositivos.* Nuestra plataforma tiene limitaciones en la cantidad de datos que puede procesar cada dispositivo, debido a las capacidades de cómputo que tiene el microcontrolador seleccionado. Es por ello que se buscará incorporar microcontroladores con mayores capacidades, que otorguen todavía de mayor poder de análisis en cada uno de los dispositivos pudiendo así, eliminar el concentrador de datos y simplificar el sistema.
- (LI3) *Comunicaciones.* Es muy importante seguir aumentando la robustez de los dispositivos a través de las tecnologías de la información y la comunicación, así como de la inteligencia artificial y electrónica. Se ha contemplado para ello, como desarrollo futuro la implementación de la tecnología 5G, que tiene la gran ventaja de soportar un mayor ancho de banda, lo que se traducirá en mayores velocidades

de descarga. Estas tecnologías permiten que los dispositivos identifiquen, de forma mucho más rápida, cuando hay una anomalía en los datos obtenidos por diferentes sensores. Pudiendo, así seguir avanzando en la robustez de la plataforma con conjuntos de datos más grandes.

- (LI4) *Investigación de sistemas predictivos eficaces.* Otro punto importante, será el continuar con la investigación de técnicas y algoritmos de Inteligencia Artificial con los cuales realizar una detección, diagnóstico y el control predictivo de situaciones de riesgo en entornos laborales. Permitiendo, gracias al uso de Smart data e IA disminuir la siniestralidad laboral de una plataforma en continua evolución, que incorpore las últimos avances de este ámbito científico.
- (LI5) *Aplicabilidad para diferentes sectores.* Por ejemplo, se plantea extender la investigación a los sectores de la movilidad y la logística, donde se podría indicar irregularidades en el tráfico, minimizar accidentes e incluso reducir el tiempo de transporte de mercancías. La aplicabilidad de este tipo de dispositivos y tecnologías se deberá validar en estos nuevos entornos y buscar una plataforma cada vez más adaptable y trasladable a diferentes tipos de industrias.
- (LI6) *Plataforma interoperable.* Una de las líneas futuras planteadas, será el convertir la plataforma en un una plataforma sencilla de manejar por los usuarios de la aplicación, sin necesidad de que tenga que estar detrás un experto. Y que de forma sencilla se puedan integrar los diferentes elementos, además de que automáticamente se apliquen las técnicas de inteligencia artificial más interesantes para ese caso de estudio.

Chapter 6

Conclusions and Future Work



VNiVERSiDAD
DE SALAMANCA

CAMPUS DE EXCELENCIA INTERNACIONAL

Conclusions and Future Work

In this Doctoral Thesis, an Edge-AIoT Platform has been presented as an effective means of improving health and safety levels in the workplace. The objective of the publications presented in this report is to present the functionality of the proposed solution. The platform is made up of three fundamental layers, whose features provide support to the worker in real time, improving the current safety conditions. It is designed to provide information about the context, emit early warnings regarding anomalies, and thanks to its processing and analysis capabilities, the collected data can be used to make predictions, with a significant improvement in the safety of workspaces.

This Chapter introduces Section 6.1, containing the conclusions that have been drawn from this Doctoral Thesis. Finally, the future lines of research that have been identified throughout the process of developing this thesis are presented in Section 6.2.

6.1. Conclusions

The growing presence of new technologies in the workplace has become more than evident in the last two decades, revolutionizing working environments and increasing productivity. In the near future, there will be an increase in the application of these technologies to ensure the well-being and health of employees, adapting PPE and making it smart and accessible to the public. The mass adoption of smart PPE will be crucial in sectors such as metallurgy, mining, fishing, commerce and construction, due to their high-risk index and high lethality. The development of smart PPE will be driven in parallel by the advancement of artificial intelligence, which enables systems to be more adaptive and meet the widespread demand for safer workplaces.

The implementation of IoT and wearable technology has revolutionized the field of smart PPE. Workers are individually monitored by the sensors implemented in their wearables, the information read by the wearables can be sent to a central node that monitors and provides personalized responses on the basis of the data received about each individual. The benefits of these technologies have already been recognized by different industries which are experimenting with their application in the workplace. The platforms that companies currently have in place focus on aspects related to production and productivity. However, the implementation of protective measures, especially when it is not possible to determine standards that guarantee the integrity of the individual, is a fundamental component in reducing these causes. Therefore, it is important to use intelligent PPE, such as belts, helmets and other devices that protect the physical integrity of the operator. In addition, with the use of Edge Computing, this solution can be integrated in areas that lack connectivity at a relatively low price; this means that it has the potential to reduce the number of accidents in any country.

The hypothesis established in this Doctoral Thesis was that it is possible to improve health and safety in the workplace by providing innovative tools in the form of personal protective equipment (PPE) capable of responding in real time to the risks present in the workplace using an Edge-AIoT platform, which can be customized and adapted to both the environment and the personal circumstances and capabilities of each worker. The approach of this hypothesis made it possible to define the main objective and the specific ones, by means of which it was possible to demonstrate the starting hypothesis. In this context, the main objective has been to design a modular platform based on Edge Computing, IoT and Artificial Intelligence technology, capable of providing real-time support in the work environment and improving working conditions in workspaces. The Action-Research methodology has been the methodological framework with which to frame the development of the Doctoral Thesis. Five phases were used to achieve the established objectives. Firstly, a review of the state of the art was carried out by conducting a Systematic Mapping Study of the Literature to support the research, allowing for the identification of other similar platforms. On this basis, a platform has been proposed that is able to address the needs and requirements associated with this field of study. For the intelligent analysis of the working environment, three pieces of equipment have been designed, namely, a helmet, a bracelet and a belt, which, combined with other equipment, allow for the evaluation and validation of the platform. The

obtained conclusions allow us to affirm that the defined objectives (OB1, OB2, OB3, OB4, OB5, OB6, OB7 and OB8) have been fulfilled and that the hypothesis has been proven. These conclusions are listed below in order:

- (OB1)** *Identify common scenarios which involve risk, with the aim of defining the platform's functionalities and the functionalities to be incorporated.*

An analysis has been carried out of all the recommendations contained in standards, regulations and risk prevention manuals. The objective of this study was to identify the risks that can be detected through compatibility with tools/devices. To this end, the situations with the highest incidence in different scenarios were identified, grouped by activity/sector. Thanks to this study, it has been possible to build models for the detection of emerging risks and to create ontologies for the association of actions and risks.

- (OB2)** *Research the factors that allow to characterize the level of risk of an activity according to the context, the worker and the procedures applied.*

As part of the research tasks, the specification of functional requirements has been carried out in order to identify the most common situations of risk that could be detected with each of the devices to be developed, seeking to achieve the greatest possible outcome. Accordingly, the functionalities that the devices must have, as well as the technical resources required for their implementation, have been defined. After formalizing the model, the rules for associating the risks with a set of preventive measures have been created, taking into account the context of the situation.

- (OB3)** *To investigate the design of new tools and solutions for the monitoring and protection of people in their work environment, based on wearable electronics and smart fabrics, for incorporation in PPE.*

For an effective prevention of injuries or fatal accidents in the work environment, the integration of electronic components is crucial given their capacity for the early detection of risks, thanks to the sensors and actuators they incorporate. An important element is the transmission of information to the higher layers of the platform using different Internet of Things protocols. Therefore, research has been carried out on different smart PPE and new generation tools, based

on innovative technologies. This research has made it possible to develop a technological framework appropriate for contextualizing situations to favor the prevention of risks.

- (OB4)** *Research and design of auxiliary equipment and systems for detection, warning and identification of risks, which can be integrated in different devices.*

Creation of devices capable of monitoring the environment and detecting elements or circumstances harmful to humans. For this purpose, all those parameters that have a direct impact on occupational health will be analyzed, with the aim of generating systems that integrate sensors to effectively monitor the conditions in indoor and outdoor locations.

- (OB5)** *Research techniques and methodologies for the processing of data collected from sensors. Use of data analysis, prevention algorithms and the use of the control platform.*

The proposed platform integrates data from different sources that require the development of connectors. The connectors interconnect the different layers and the ingestion of the collected information, thus achieving the fusion of information with which to aggregate very diverse data. In addition, as a result of the development, a set of ad-hoc tools have been created, which allow to perform analyses for improved security. Thus, the best methodologies and algorithms for knowledge extraction have been integrated from the available information, which will serve as the basis for the scenario detection systems and the prediction and solution proposal modules.

- (OB6)** *Integrate the features provided by AIoT and Smart Data to obtain a platform that provides operational support and is capable of evolving and learning.*

The different layers have been integrated and their components are interoperable. This involves the selection and implementation of connectors and protocols for integration between the different components of the platform using agile methodologies. The platform enhances the information it handles with intelligent data processing models (Smart Data) in real time. This has made it necessary to define algorithms and build a knowledge base on which to predict scenarios and characterize risk situations, providing the system with the capacity to understand the situation.

(OB7) *Design a scalable Edge AIoT modular platform for the ingestion of data from different devices, incorporating Artificial Intelligence algorithms for the detection, diagnosis and predictive control of risk situations in working environments.*

The platform incorporates two fundamental processing blocks (Edge and Cloud Computing), where the developed capabilities include the interconnection between the blocks for data exchange, as well as the analytical functionalities to provide service to the different layers of the system. Given that the computing capacity is at the edge, it is possible to analyze data from the different devices both with and without an internet connection, as well as to improve the performance of the PPE devices in detection tasks, significantly increasing security, energy efficiency and responsiveness.

(OB8) *Validation of the system in different working environments for the analysis and evaluation of the correct performance of the obtained results.*

A series of functional tests were carried out to debug errors and correct and improve the platform, which has resulted in a number of reports and recommendations for an improved functional version of the system. To this end, a series of metrics have been established to measure the performance parameters of each of the components, as well as the platform as a whole. Finally, the platform was enhanced through iterative development in order to deploy the refined beta version of the platform in the Cloud and on the Edge.

6.2. Future Lines of Research

Future lines of research will focus on overcoming the limitations that have been found, once the objectives that were initially proposed during the development of the Doctoral Thesis have been achieved. These new lines of research can be summarized as described below:

(RL1) *Design of new equipment.* Future research must continue to design new protection tools and equipment for different fields of application, adapting the technology to the safety needs, with the aim of generating an economic benefit for the sectors that use the developed solution.

- (RL2)** *Data processing in the devices.* Our platform has limitations in terms of the amount of data that can be processed by each device, due to the computational capabilities of the selected microcontroller. For this reason, future research will focus on incorporating microcontrollers with higher capacities, which will provide even greater analytical capabilities to each device, thus eliminating the data concentrator and simplifying the system.
- (RL3)** *Communications.* It is very important to continue increasing the robustness of devices through information and communication technologies, as well as artificial intelligence and electronics. For this purpose, the implementation of 5G technology has been contemplated as a future development, which has the great advantage of supporting a higher bandwidth, which will result in faster download rates. These technologies enable devices to identify anomalies in the data much faster. Thus, being able to further increase the robustness of the platform with larger datasets.
- (RL4)** *Research on effective predictive systems.* Another important element will be to continue researching Artificial Intelligence techniques and algorithms for the detection, diagnosis and predictive control of risk situations in working environments. Thanks to the use of smart data and AI, this will reduce the occupational accident rate through a platform in continuous evolution, incorporating the latest advances in this area of research.
- (RL5)** *Applicability to a variety of sectors.* This research could be extended to the mobility and logistics sectors, for example, where it could indicate irregularities in traffic, minimize accidents and even reduce the time taken to transport goods. The applicability of this type of devices and technologies will have to be validated in these new environments and an increasingly adaptable and transferable platform will be sought for different types of industries.
- (RL6)** *Interoperable platform.* One of the future lines of research will focus on making the platform easy to operate by non-expert users. In addition, the different elements should be easily integrated, and the most appropriate artificial intelligence techniques should be automatically applied to the case study.

Bibliografía

- Abdelhamid, T. S., & Everett, J. G. (2000). Identifying root causes of construction accidents. *Journal of construction engineering and management*, 126(1), 52–60.
- Adjiski, V., Despodov, Z., Mirakovski, D., & Serafimovski, D. (2019). System architecture to bring smart personal protective equipment wearables and sensors to transform safety at work in the underground mining industry. *Rudarsko-geološko-naftni zbornik*, 34(1), 37–44.
- Akbar-Khanzadeh, F., Bisesi, M. S., & Rivas, R. D. (1995). Comfort of personal protective equipment. *Applied ergonomics*, 26(3), 195–198.
- Alonso, R. S., Sittón-Candanedo, I., Casado-Vara, R., Prieto, J., & Corchado, J. M. (2020). Deep reinforcement learning for the management of software-defined networks and network function virtualization in an edge-iot architecture. *Sustainability*, 12(14), 5706.
- Alonso, R. S., Sittón-Candanedo, I., García, Ó., Prieto, J., & Rodríguez-González, S. (2020). An intelligent edge-iot platform for monitoring livestock and crops in a dairy farming scenario. *Ad Hoc Networks*, 98, 102047.
- Alsulami, M. H., Atkins, A. S., & Campion, R. J. (2016). The use of smart watches to monitor heart rates in elderly people: A complementary approach. En *2016 ieee/acs 13th international conference of computer systems and applications (aiccsa)* (pp. 1–6).
- Amft, O., Habetha, J., & Van Langenhove, L. (2007). Smart medical textiles for monitoring patients with heart conditions. *Smart Textiles for Medicine and Healthcare Materials, Systems and Applications*; Woodhead Publishing Limited: Cambridge, UK, 275–301.
- Araújo, A., Portugal, D., Couceiro, M. S., & Rocha, R. P. (2015). Integrating arduino-based educational mobile robots in ros. *Journal of Intelligent & Robotic Systems*, 77(2), 281–298.

- Avgeris, M., Spatharakis, D., Dechouniotis, D., Kalatzis, N., Roussaki, I., & Papavassiliou, S. (2019). Where there is fire there is smoke: A scalable edge computing framework for early fire detection. *Sensors*, 19(3), 639.
- Azar, A. T., Elshazly, H. I., Hassanien, A. E., & Elkorany, A. M. (2014). A random forest classifier for lymph diseases. *Computer methods and programs in biomedicine*, 113(2), 465–473.
- Badri, A., Boudreau-Trudel, B., & Souissi, A. S. (2018). Occupational health and safety in the industry 4.0 era: A cause for major concern? *Safety science*, 109, 403–411.
- Bajo, J., De Paz, J. F., Villarrubia, G., & Corchado, J. M. (2015). Self-organizing architecture for information fusion in distributed sensor networks. *International Journal of Distributed Sensor Networks*, 11(3), 231073.
- Bao, L., & Intille, S. S. (2004). Activity recognition from user-annotated acceleration data. En *International conference on pervasive computing* (pp. 1–17).
- Barata, J., & da Cunha, P. R. (2019). The viable smart product model: Designing products that undergo disruptive transformations. *Cybernetics and Systems*, 50(7), 629–655.
- Barro-Torres, S., Fernández-Caramés, T. M., Pérez-Iglesias, H. J., & Escudero, C. J. (2012). Real-time personal protective equipment monitoring system. *Computer Communications*, 36(1), 42–50.
- Baskerville, R. L. (1999). Investigating information systems with action research. *Communications of the association for information systems*, 2(1), 19.
- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS journal of photogrammetry and remote sensing*, 114, 24–31.
- Bensel, C. K., & Santee, W. R. (2006). Use of personal protective equipment in the workplace.
- Bleser, G., Damen, D., Behera, A., Hendeby, G., Mura, K., Miezal, M., ... et al. (2015). Cognitive learning, monitoring and assistance of industrial workflows using egocentric sensor networks. *PloS one*, 10(6), e0127769.
- Boden, L. I., & Ruser, J. W. (2003). Workers' compensation "reforms," choice of medical care provider, and reported workplace injuries. *Review of Economics and Statistics*, 85(4), 923–929.
- Bokor, Z. (2012). Integrating logistics cost calculation into production costing. *Acta Polytechnica Hungarica*, 9(3), 163–181.

- Bonato, P. (2010). Wearable sensors and systems. *IEEE Engineering in Medicine and Biology Magazine*, 29(3), 25–36.
- Boutellaaa, E., Kerdjidj, O., & Ghanem, K. (2019). Covariance matrix based fall detection from multiple wearable sensors. *Journal of biomedical informatics*, 94, 103189.
- Boyes, H., Hallaq, B., Cunningham, J., & Watson, T. (2018). The industrial internet of things (iiot): An analysis framework. *Computers in industry*, 101, 1–12.
- Cambraia, F. B., Saurin, T. A., & Formoso, C. T. (2010). Identification, analysis and dissemination of information on near misses: A case study in the construction industry. *Safety Science*, 48(1), 91–99.
- Campero-Jurado, I., Márquez-Sánchez, S., Quintanar-Gómez, J., Rodríguez, S., & Corchado, J. M. (2020). Smart helmet 5.0 for industrial internet of things using artificial intelligence. *Sensors*, 20(21), 6241.
- Casado-Vara, R., Chamoso, P., De la Prieta, F., Prieto, J., & Corchado, J. M. (2019). Non-linear adaptive closed-loop control system for improved efficiency in iot-blockchain management. *Information Fusion*, 49, 227–239.
- Casado-Vara, R., González-Briones, A., Prieto, J., & Corchado, J. M. (2018). Smart contract for monitoring and control of logistics activities: pharmaceutical utilities case study. En *The 13th international conference on soft computing models in industrial and environmental applications* (pp. 509–517).
- Casado-Vara, R., Novais, P., Gil, A. B., Prieto, J., & Corchado, J. M. (2019). Distributed continuous-time fault estimation control for multiple devices in iot networks. *IEEE Access*, 7, 11972–11984.
- Casado-Vara, R., Prieto-Castrillo, F., & Corchado, J. M. (2018). A game theory approach for cooperative control to improve data quality and false data detection in wsn. *International Journal of Robust and Nonlinear Control*, 28(16), 5087–5102.
- Cella, C. H., Duffy, G. W., & JR., M. D., Jeffrey P. McGuckin. (2019). Methods and systems for data collection, learning, and streaming of machine signals for analytics and maintenance using the industrial internet of things. u.s. patent application us16/369,210, 07. July.
- Cella, C. H., Duffy, G. W., & McGuckin., J. P. (2019). Methods and systems for the industrial internet of things. u.s. patent no. 10,394,210. 27. Aug..
- Cerda, J., & Cifuentes, L. (2012). Uso de curvas roc en investigación clínica: Aspectos teórico-prácticos. *Revista chilena de infectología*, 29(2), 138–141.
- Chabot, M., Delaware, L., McCarley, S., Little, C., Nye, A., & Anderson, E. (2019).

- Living in place: The impact of smart technology. *Current Geriatrics Reports*, 8(3), 232–238.
- Chae, H., Ko, M., Kim, H., Kim, K., Choi, D., Kim, K., & Lee, K. (2017). Development trends of smart personal protective equipment for agricultural health and safety. *J. Ergon. Soc. Korea*, 36, 677–691.
- Chamoso, P., González-Briones, A., Rivas, A., De La Prieta, F., & Corchado, J. M. (2019). Social computing in currency exchange. *Knowledge and Information Systems*, 61(2), 733–753.
- Chamoso, P., González-Briones, A., Rodríguez, S., & Corchado, J. M. (2018). Tendencies of technologies and platforms in smart cities: a state-of-the-art review. *Wireless Communications and Mobile Computing*, 2018.
- Chamoso, P., Paz, J. F. D., Bajo, J., & Villarrubia, G. (2016). Intelligent control of energy distribution networks. En *International conference on practical applications of agents and multi-agent systems* (pp. 99–107).
- Chamoso, P., Prieta, F. D. L., Eibenstein, A., Santos-Santos, D., Tizio, A., & Vittorini, P. (2017). A device supporting the self management of tinnitus. En *International conference on bioinformatics and biomedical engineering* (pp. 399–410).
- Chamoso, P., Rodríguez, S., de la Prieta, F., & Bajo, J. (2018). Classification of retinal vessels using a collaborative agent-based architecture. *Ai Communications*, 31(5), 427–444.
- Champoux, D., & Brun, J.-P. (2003). Occupational health and safety management in small size enterprises: an overview of the situation and avenues for intervention and research. *Safety science*, 41(4), 301–318.
- Chen, G., & Kotz, D. (2000). A survey of context-aware mobile computing research.
- Chen, M., Zhang, Y., Qiu, M., Guizani, N., & Hao, Y. (2018). Spha: Smart personal health advisor based on deep analytics. *IEEE Communications Magazine*, 56(3), 164–169.
- Chen, Y., Zhong, K., Zhang, J., Sun, Q., Zhao, X., & et al. (2016). Lstm networks for mobile human activity recognition. En *Proceedings of the 2016 international conference on artificial intelligence: Technologies and applications, bangkok, thailand* (pp. 24–25).
- Chen, Z.-Y., & Kuo, R. (2017). Evolutionary algorithm-based radial basis function neural network training for industrial personal computer sales forecasting. *Computational Intelligence*, 33(1), 56–76.

- Chevalier, Y., Compagna, L., Cuellar, J., Drielsma, P. H., Mantovani, J., Mödersheim, S., & Vigneron, L. (2004). A high level protocol specification language for industrial security-sensitive protocols. En *Workshop on specification and automated processing of security requirements-saps'2004* (pp. 13–p).
- Chi, S., & Han, S. (2013). Analyses of systems theory for construction accident prevention with specific reference to osha accident reports. *International Journal of Project Management*, 31(7), 1027–1041.
- Chimeno, S. G., Fernández, J. D., Sánchez, S. M., Ramón, P. P., Ospina, Ó. M. S., Muñoz, M. V., & Hernández, A. G. (2018). Domestic violence prevention system. En *International symposium on distributed computing and artificial intelligence* (pp. 10–14).
- Cho, G., Jeong, K., Paik, M. J., Kwun, Y., & Sung, M. (2011). Performance evaluation of textile-based electrodes and motion sensors for smart clothing. *IEEE Sensors Journal*, 11(12), 3183–3193.
- Choudhry, R. M., & Fang, D. (2008). Why operatives engage in unsafe work behavior: Investigating factors on construction sites. *Safety science*, 46(4), 566–584.
- Connor, R. A. (2020, abril 21). *Wearable device for the arm with close-fitting biometric sensors*. Google Patents. (US Patent 10,627,861)
- Consolvo, S., McDonald, D. W., Toscos, T., Chen, M. Y., Froehlich, J., Harrison, B., ... et al. (2008). Activity sensing in the wild: a field trial of ubifit garden. En *Proceedings of the sigchi conference on human factors in computing systems* (pp. 1797–1806).
- Coria, J. A. G., Castellanos-Garzón, J. A., & Corchado, J. M. (2014). Intelligent business processes composition based on multi-agent systems. *Expert Systems with Applications*, 41(4), 1189–1205.
- Davis, J., & Goadrich, M. (2006). The relationship between precision-recall and roc curves. En *Proceedings of the 23rd international conference on machine learning* (pp. 233–240).
- De la Prieta, F., Gil, A. B., Rodríguez-González, S., & Corchado, J. M. (2014). Cloud computing and multi agent system to improve learning object paradigm. *IxD&A*, 23, 38–49.
- de Trabajo y Economía Social, M. (2021, marzo). *Estadística de accidentes de trabajo 2020* (Inf. Téc.). Autor. Descargado de https://www.mites.gob.es/estadisticas/eat/eat22_02/ATR_02_2022_Resumen.pdf

- Dhull, R., Chava, D., Kumar, D. V., Prasad, K. M., Samudrala, G., & Bhargav, M. V. (2020). Pandemic stabilizer using smartwatch. En *2020 international conference on decision aid sciences and application (dasa)* (pp. 860–866).
- Dong, X. L., & Srivastava, D. (2013). Big data integration. En *2013 ieee 29th international conference on data engineering (icde)* (pp. 1245–1248).
- Dunne, L. E., Gioberto, G., & Simon, C. (2015). E-textiles in the apparel factory: leveraging cut-and-sew technology toward the next generation of smart garments. En *Fundamentals of wearable computers and augmented reality*.
- Duong, T. V., Bui, H. H., Phung, D. Q., & Venkatesh, S. (2005). Activity recognition and abnormality detection with the switching hidden semi-markov model. En *2005 ieee computer society conference on computer vision and pattern recognition (cvpr'05)* (Vol. 1, pp. 838–845).
- Dupuis, H., & Zerlett, G. (1987). Whole-body vibration and disorders of the spine. *International archives of occupational and environmental health*, 59(4), 323–336.
- Eden, C., & Ackermann, F. (2018). Theory into practice, practice to theory: Action research in method development. *European Journal of Operational Research*, 271(3), 1145–1155.
- Eckelaert, L., Dhondt, S., Oeij, P., Pot, F., Nicolescu, G. I., Webster, J., & Elsler, D. (2012). *Review of workplace innovation and its relation with occupational safety and health*. Bilbao: European Agency for Safety and Health at Work.
- Fahim, M., Fatima, I., Lee, S., & Park, Y.-T. (2013). Efm: evolutionary fuzzy model for dynamic activities recognition using a smartphone accelerometer. *Applied intelligence*, 39(3), 475–488.
- Farringdon, J., Moore, A. J., Tilbury, N., Church, J., & Biemond, P. D. (1999). Wearable sensor badge and sensor jacket for context awareness. En *Digest of papers. third international symposium on wearable computers* (pp. 107–113).
- Fathallah, H., Lecuire, V., Rondeau, E., & Le Calvé, S. (2015). Development of an iot-based system for real time occupational exposure monitoring. En *The tenth international conference on systems and networks communications, icsnc 2015*.
- Fernández Canelas, J. Á., Martín Martín, Q., Corchado Rodríguez, J. M., & et al. (2014). Decision making intelligent agent on sox compliance over the imports process.
- Fernández-Muñiz, B., Montes-Peón, J. M., & Vázquez-Ordás, C. J. (2012). Safety climate in ohsas 18001-certified organisations: Antecedents and consequences of safety behaviour. *Accident Analysis & Prevention*, 45, 745–758.

- Fischer II, W. A., Weber, D. J., & Wohl, D. A. (2015). Personal protective equipment: protecting health care providers in an ebola outbreak. *Clinical therapeutics*, 37(11), 2402–2410.
- Fishta, A., Van den Heuvel, S., Euler, U., Nold, A., Mattioli, S., & Verbeek, J. (s.f.). Priority setting for future european occupational safety and health research.
- Fitton, D., Sundramoorthy, V., Kortuem, G., Brown, J., Efstratiou, C., Finney, J., & Davies, N. (2008). Exploring the design of pay-per-use objects in the construction domain. En *European conference on smart sensing and context* (pp. 192–205).
- Fortino, G., Galzarano, S., Gravina, R., & Li, W. (2015). A framework for collaborative computing and multi-sensor data fusion in body sensor networks. *Information Fusion*, 22, 50–70.
- Frederick, C., W.H.; Miller. (2017). U.s. patent application no. 29/234,869, 16. January.
- Friend, M. A., & Kohn, J. P. (2018). *Fundamentals of occupational safety and health*. Rowman & Littlefield.
- Gardner, R. (2003). Overview and characteristics of some occupational exposures and health risks on offshore oil and gas installations. *Annals of Occupational Hygiene*, 47(3), 201–210.
- Gazafroudi, A. S., Soares, J., Ghazvini, M. A. F., Pinto, T., Vale, Z., & Corchado, J. M. (2019). Stochastic interval-based optimal offering model for residential energy management systems by household owners. *International Journal of Electrical Power & Energy Systems*, 105, 201–219.
- Gil, R. A., Johanyák, Z. C., Kovács, T., & et al. (2018). Surrogate model based optimization of traffic lights cycles and green period ratios using microscopic simulation and fuzzy rule interpolation. *Int. J. Artif. Intell.*, 16(1), 20–40.
- Gjoreski, H., Lustrek, M., & Gams, M. (2011). Accelerometer placement for posture recognition and fall detection. En *2011 seventh international conference on intelligent environments* (pp. 47–54).
- Glendon, A. I., & Litherland, D. K. (2001). Safety climate factors, group differences and safety behaviour in road construction. *Safety science*, 39(3), 157–188.
- Gnoni, M. G., Bragatto, P. A., Milazzo, M. F., & Setola, R. (2020). Integrating iot technologies for an “intelligent” safety management in the process industry. *Procedia manufacturing*, 42, 511–515.
- Godfrey, A., Conway, R., Meagher, D., & ÓLaighin, G. (2008). Direct measurement of human movement by accelerometry. *Medical engineering & physics*, 30(10),

- 1364–1386.
- Gonzalez, I. V., & et al. (2007). *Formación superior en prevención de riesgos laborales. parte obligatoria y común*. Lex Nova.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Gopalsamy, C., Park, S., Rajamanickam, R., & Jayaraman, S. (1999). The wearable motherboard™: The first generation of adaptive and responsive textile structures (arts) for medical applications. *Virtual Reality*, 4(3), 152–168.
- Gope, C. (2015). Use of a smart watch for seizure/abnormal motion activity monitoring and tracking. *Epilepsy & Behavior*, 100(46), 52–53.
- Granerud, L. (2011). Social responsibility as an intermediary for health and safety in small firms. *International Journal of Workplace Health Management*.
- Grant, A. M., Christianson, M. K., & Price, R. H. (2007). Happiness, health, or relationships? managerial practices and employee well-being tradeoffs. *Academy of management perspectives*, 21(3), 51–63.
- Han, Y., & Song, Y. (2003). Condition monitoring techniques for electrical equipment-a literature survey. *IEEE Transactions on Power delivery*, 18(1), 4–13.
- Harms, H., Amft, O., Roggen, D., & Tröster, G. (2008). Smash: A rapid prototyping garment. En *2nd international scientific conference 'textiles of the future' (futurotextiel 2008)*.
- Harms, H., Amft, O., & Tröster, G. (2012). Does loose fitting matter? predicting sensor performance in smart garments. En *Proceedings of the 7th international conference on body area networks* (pp. 1–4).
- Hawley-Hague, H., Boulton, E., Hall, A., Pfeiffer, K., & Todd, C. (2014). Older adults' perceptions of technologies aimed at falls prevention, detection or monitoring: a systematic review. *International journal of medical informatics*, 83(6), 416–426.
- Henley, E. J., & Kumamoto, H. (1985). Designing for reliability and safety control.
- Heras, S., De la Prieta, F., Julian, V., Rodríguez, S., Botti, V., Bajo, J., & Corchado, J. M. (2012). Agreement technologies and their use in cloud computing environments. *Progress in Artificial Intelligence*, 1(4), 277–290.
- Huang, S., Chen, Y.-C., & Liao, S.-H. (2018). Wearable human body falling detection device. En *Proceedings of the international conference on scientific computing (csc)* (pp. 201–203).
- Incel, O. D., Kose, M., & Ersoy, C. (2013). A review and taxonomy of activity recognition on mobile phones. *BioNanoScience*, 3(2), 145–171.

- Iranitalab, A., & Khattak, A. (2017). Comparison of four statistical and machine learning methods for crash severity prediction. *Accident Analysis & Prevention*, 108, 27–36.
- Islam, A. (2020). *Use of ppe in response of coronavirus (covid-19): a smart solution to global economic challenges*. Ph. D. Thesis, Putra Business School, Seri Kembangan, Malaysi.
- Jackowski, K., Jankowski, D., Quintián, H., Corchado, E., & Woźniak, M. (2016). Modelling dental milling process with machine learning-based regression algorithms. En *Proceedings of the 9th international conference on computer recognition systems cores 2015* (pp. 701–711).
- Jararweh, Y., Doulat, A., AlQudah, O., Ahmed, E., Al-Ayyoub, M., & Benkhelifa, E. (2016). The future of mobile cloud computing: integrating cloudlets and mobile edge computing. En *2016 23rd international conference on telecommunications (ict)* (pp. 1–5).
- Jedari, E., Wu, Z., Rashidzadeh, R., & Saif, M. (2015). Wi-fi based indoor location positioning employing random forest classifier. En *2015 international conference on indoor positioning and indoor navigation (ipin)* (pp. 1–5).
- Johnson, A. E., Ghassemi, M. M., Nemati, S., Niehaus, K. E., Clifton, D. A., & Clifford, G. D. (2016). Machine learning and decision support in critical care. *Proceedings of the IEEE*, 104(2), 444–466.
- Kajornkasirat, S., Chanapai, N., & Hnusuwan, B. (2018). Smart health monitoring system with iot. En *2018 ieee symposium on computer applications & industrial electronics (iscaie)* (pp. 206–211).
- Kalchbrenner, N., Grefenstette, E., & Blunsom, P. (2014). A convolutional neural network for modelling sentences. *arXiv preprint arXiv:1404.2188*.
- Karakaya, M., Sengül, G., & Bostan, A. (2017). Remotely monitoring activities of the elders using smart watches. *Int. J. Sci. Res. Inf. Syst. Eng.*, 3, 56.
- Karr, A. F., Lin, X., Sanil, A. P., & Reiter, J. P. (2009). Privacy-preserving analysis of vertically partitioned data using secure matrix products. *Journal of Official Statistics*, 25(1), 125.
- Khalilia, M., Chakraborty, S., & Popescu, M. (2011). Predicting disease risks from highly imbalanced data using random forest. *BMC medical informatics and decision making*, 11(1), 1–13.
- Kim, S. H., Wang, C., Min, S. D., & Lee, S. H. (2018). Safety helmet wearing

- management system for construction workers using three-axis accelerometer sensor. *Applied Sciences*, 8(12), 2400.
- Krupitzer, C., Sztyler, T., Edinger, J., Breitbach, M., Stuckenschmidt, H., & Becker, C. (2019). Beyond position-awareness—extending a self-adaptive fall detection system. *Pervasive and Mobile Computing*, 58, 101026.
- Kumari, P., Mathew, L., & Syal, P. (2017). Increasing trend of wearables and multimodal interface for human activity monitoring: A review. *Biosensors and Bioelectronics*, 90, 298–307.
- Kwapisz, J. R., Weiss, G. M., & Moore, S. A. (2011). Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter*, 12(2), 74–82.
- Lara, O. D., & Labrador, M. A. (2012). A mobile platform for real-time human activity recognition. En *2012 ieee consumer communications and networking conference (ccnc)* (pp. 667–671).
- Lasi, H., Fettke, P., Kemper, H.-G., Feld, T., & Hoffmann, M. (2014). Industry 4.0. *Business & information systems engineering*, 6(4), 239–242.
- Laxhammar, R., Falkman, G., & Sviestins, E. (2009). Anomaly detection in sea traffic—a comparison of the gaussian mixture model and the kernel density estimator. En *2009 12th international conference on information fusion* (pp. 756–763).
- Leake, D. B. (1996). Case-based reasoning: experiences, lessons, and future directions.
- Lee, J., Davari, H., Singh, J., & Pandhare, V. (2018). Industrial artificial intelligence for industry 4.0-based manufacturing systems. *Manufacturing letters*, 18, 20–23.
- Lee, J.-Y., Park, J., Park, H., Coca, A., Kim, J.-H., Taylor, N. A., ... Tochihara, Y. (2015). What do firefighters desire from the next generation of personal protective equipment? outcomes from an international survey. *Industrial Health*.
- Lenzerini, M. (2002). Data integration: A theoretical perspective. En *Proceedings of the twenty-first acm sigmod-sigact-sigart symposium on principles of database systems* (pp. 233–246).
- Leonavičiūtė, G., Déjus, T., & Antuchevičienė, J. (2016). Analysis and prevention of construction site accidents. *Gradžinė*, 68(05.), 399–410.
- Li, L., Hansman, R. J., Palacios, R., & Welsch, R. (2016). Anomaly detection via a gaussian mixture model for flight operation and safety monitoring. *Transportation Research Part C: Emerging Technologies*, 64, 45–57.
- Li, P., Meziane, R., Otis, M. J.-D., Ezzaidi, H., & Cardou, P. (2014). A smart safety helmet using imu and eeg sensors for worker fatigue detection. En *2014 ieee*

- international symposium on robotic and sensors environments (rose) proceedings* (pp. 55–60).
- Li, T.-c., Su, J.-y., Liu, W., & Corchado, J. M. (2017). Approximate gaussian conjugacy: parametric recursive filtering under nonlinearity, multimodality, uncertainty, and constraint, and beyond. *Frontiers of Information Technology & Electronic Engineering*, 18(12), 1913–1939.
- Maglogiannis, I., Ioannou, C., Spyroglou, G., & Tsanakas, P. (2014). Fall detection using commodity smart watch and smart phone. En *Ifip international conference on artificial intelligence applications and innovations* (pp. 70–78).
- Magno, M., Brunelli, D., Sigrist, L., Andri, R., Cavigelli, L., Gomez, A., & Benini, L. (2016). Infinitime: Multi-sensor wearable bracelet with human body harvesting. *Sustainable Computing: Informatics and Systems*, 11, 38–49.
- Manisha, M., Neeraja, K., Sindhura, V., & Ramaya, P. (2016). Iot on heart attack detection and heart rate monitoring. *International Journal of Innovation in Engineering and Technology (IJIET)*, 196.
- Mann, S. (2012). Wearable computing. *Encyclopedia of Human-Computer Interaction*.
- Maria, A. R., Sever, P., & George, S. (2018). Miot applications for wearable technologies used for health monitoring. En *2018 10th international conference on electronics, computers and artificial intelligence (ecai)* (pp. 1–4).
- Márquez-Sánchez, S., Campero-Jurado, I., Herrera-Santos, J., Rodríguez, S., & Corchado, J. M. (2021). Intelligent platform based on smart ppe for safety in workplaces. *Sensors*, 21(14), 4652.
- Márquez-Sánchez, S., Campero-Jurado, I., Robles-Camarillo, D., Rodríguez, S., & Corchado-Rodríguez, J. M. (2021). Besafe b2. 0 smart multisensory platform for safety in workplaces. *Sensors*, 21(10), 3372.
- Matías, J. M., Rivas, T., Martín, J., & Taboada, J. (2008). A machine learning methodology for the analysis of workplace accidents. *International Journal of Computer Mathematics*, 85(3-4), 559–578.
- Mattmann, C., Amft, O., Harms, H., Troster, G., & Clemens, F. (2007). Recognizing upper body postures using textile strain sensors. En *2007 11th ieee international symposium on wearable computers* (pp. 29–36).
- Miorandi, D., Sicari, S., De Pellegrini, F., & Chlamtac, I. (2012). Internet of things: Vision, applications and research challenges. *Ad hoc networks*, 10(7), 1497–1516.
- Mobley, R. K. (2002). *An introduction to predictive maintenance*. Elsevier.

- Mondal, S. (2008). Phase change materials for smart textiles—an overview. *Applied thermal engineering*, 28(11-12), 1536–1550.
- Mukhopadhyay, S. C. (2014). Wearable sensors for human activity monitoring: A review. *IEEE sensors journal*, 15(3), 1321–1330.
- Nguyen, D. N. (2017, octubre 31). *Smart watch with automatic voice recording and alarm*. Google Patents. (US Patent 9,805,576)
- Nihan, C. E. (2013). Healthier? more efficient? fairer? an overview of the main ethical issues raised by the use of ubicomp in the workplace. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 2(1), 29.
- Nithya, T., Ezak, M. M., Kumar, K. R., Vignesh, V., & Vimala, D. (2018). Rescue and protection system for underground mine workers based on zigbee. *Int. J. Recent Res. Asp*, 4(4), 194–197.
- Niu, Y., Lu, W., Xue, F., Liu, D., Chen, K., Fang, D., & Anumba, C. (2019). Towards the “third wave”: An sco-enabled occupational health and safety management system for construction. *Safety science*, 111, 213–223.
- Nouri, J., Omidvari, M., & Tehrani, S. (2010). Risk assessment and crisis management in gas stations.
- Noury, N., Rumeau, P., Bourke, A., ÓLaighin, G., & Lundy, J. (2008). A proposal for the classification and evaluation of fall detectors. *Irbm*, 29(6), 340–349.
- Nowaková, J., Prílepková, M., & Snášel, V. (2017). Medical image retrieval using vector quantization and fuzzy s-tree. *Journal of medical systems*, 41(2), 1–16.
- Ohtaki, Y., Sagawa, K., & Inooka, H. (2001). A method for gait analysis in a daily living environment by body-mounted instruments. *JSME International Journal Series C Mechanical Systems, Machine Elements and Manufacturing*, 44(4), 1125–1132.
- O’Leary, D. E., Kuokka, D., & Plant, R. (1997). Artificial intelligence and virtual organizations. *Communications of the ACM*, 40(1), 52–59.
- Oliveira, T., Neves, J., & Novais, P. (2012). Guideline formalization and knowledge representation for clinical decision support. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 1(2), 1–11.
- Ordóñez, F. J., & Roggen, D. (2016). Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors*, 16(1), 115.
- Organization, W. H., & et al. (2021). Who/ilo joint estimates of the work-related burden of disease and injury, 2000-2016: technical report with data sources and methods. En *Who/ilo joint estimates of the work-related burden of disease and*

- injury, 2000-2016: technical report with data sources and methods.*
- Ouwerkerk, M., Dandine, P., Bolio, D., Kocielnik, R., Mercurio, J., Huijgen, H., & Westerink, J. (2013). Wireless multi sensor bracelet with discreet feedback. En *Proceedings of the 4th conference on wireless health* (pp. 1–8).
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International journal of remote sensing*, 26(1), 217–222.
- Parara, A., & Sekka, S. (2016, noviembre 24). *Wearable care security smart watch device*. Google Patents. (US Patent App. 15/162,121)
- Park, S., & Jayaraman, S. (2003). Enhancing the quality of life through wearable technology. *IEEE Engineering in medicine and biology magazine*, 22(3), 41–48.
- Pavón, I., Sigcha, L., Arezes, P., Costa, N., Arcas, G., & López, J. (2018). Wearable technology for occupational risk assessment: Potential avenues for applications. En *Occupational safety and hygiene vi* (pp. 447–452). CRC Press.
- Pavón, I., Sigcha, L., López, J., & De Arcas, G. (2017). Wearable technology usefulness for occupational risk prevention: Smartwatches for hand-arm vibration exposure assessment. En *Occupational safety and hygiene v* (pp. 77–82). CRC Press.
- Perez, M. N., Mata, F. J. A., Rodriguez, V. M. Z., & Zhang, S. (2015). Pervasive healthcare monitoring system. En *2015 ieee 12th intl conf on ubiquitous intelligence and computing and 2015 ieee 12th intl conf on autonomic and trusted computing and 2015 ieee 15th intl conf on scalable computing and communications and its associated workshops (uic-atc-scalcom)* (pp. 1712–1716).
- Plötz, T., Hammerla, N. Y., & Olivier, P. L. (2011). Feature learning for activity recognition in ubiquitous computing. En *Twenty-second international joint conference on artificial intelligence*.
- Podgorski, D., Majchrzycka, K., Dabrowska, A., Gralewicz, G., & Okrasa, M. (2017). Towards a conceptual framework of osh risk management in smart working environments based on smart ppe, ambient intelligence and the internet of things technologies. *International Journal of Occupational Safety and Ergonomics*, 23(1), 1–20.
- Porter, M. E., & Heppelmann, J. E. (2015). How smart, connected products are transforming companies. *Harvard business review*, 93(10), 96–114.
- Post, E. R., & Orth, M. (1997). Smart fabric, or "wearable clothing". En *Digest of papers. first international symposium on wearable computers* (pp. 167–168).

- Post, E. R., Orth, M., Cooper, E., & Smith, J. R. (2001, abril 3). *Electrically active textiles and articles made therefrom*. Google Patents. (US Patent 6,210,771)
- Post, E. R., Orth, M., Russo, P. R., & Gershenfeld, N. (2000). E-broidery: Design and fabrication of textile-based computing. *IBM Systems journal*, 39(3.4), 840–860.
- Pozna, C., Precup, R.-E., Tar, J. K., Škrjanc, I., & Preitl, S. (2010). New results in modelling derived from bayesian filtering. *Knowledge-Based Systems*, 23(2), 182–194.
- Prado, M., Reina-Tosina, J., & Roa, L. (2002). Distributed intelligent architecture for falling detection and physical activity analysis in the elderly. En *Proceedings of the second joint 24th annual conference and the annual fall meeting of the biomedical engineering society/engineering in medicine and biology* (Vol. 3, pp. 1910–1911).
- Puente Fernández, J. A., García Villalba, L. J., & Kim, T.-H. (2018). Software defined networks in wireless sensor architectures. *Entropy*, 20(4), 225.
- Puig Ramírez, J. (2010). Asset optimization and predictive maintenance in discrete manufacturing industry.
- Qian, Z.-H., & Wang, Y.-J. (2013). Internet of things-oriented wireless sensor networks review. , 35(1), 215–227.
- Qiang, C., Ji-Ping, S., Zhe, Z., & Fan, Z. (2009). Zigbee based intelligent helmet for coal miners. En *2009 wri world congress on computer science and information engineering* (Vol. 3, pp. 433–435).
- Rachuri, K. K., Musolesi, M., Mascolo, C., Rentfrow, P. J., Longworth, C., & Aucinas, A. (2010). Emotionsense: a mobile phones based adaptive platform for experimental social psychology research. En *Proceedings of the 12th acm international conference on ubiquitous computing* (pp. 281–290).
- Raj, K. D., Chairat, A., Timtong, V., Dailey, M. N., & Ekpanyapong, M. (2018). Helmet violation processing using deep learning. En *2018 international workshop on advanced image technology (iwait)* (pp. 1–4).
- Rajendran, S. D., Wahab, S. N., & Yeap, S. P. (2020). Design of a smart safety vest incorporated with metal detector kits for enhanced personal protection. *Safety and health at work*, 11(4), 537–542.
- Rasmussen, C. (1999). The infinite gaussian mixture model. *Advances in neural information processing systems*, 12.
- Reeder, B., & David, A. (2016). Health at hand: A systematic review of smart watch uses for health and wellness. *Journal of biomedical informatics*, 63, 269–276.

- Reynolds, D. A. (2009). Gaussian mixture models. *Encyclopedia of biometrics*, 741(659-663).
- Riverola, F. F., & Corchado, J. M. (2000). Sistemas híbridos neuro-simbólicos: una revisión. *Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial*, 4(11), 12–26.
- Rocha, J. G., Goncalves, L. M., Rocha, P., Silva, M. P., & Lanceros-Mendez, S. (2009). Energy harvesting from piezoelectric materials fully integrated in footwear. *IEEE transactions on industrial electronics*, 57(3), 813–819.
- Rodriguez, S., & Corchado, J. M. (2020). Smart belt design by naive bayes classifier for standard industrial protection equipment integration. *Int. J. Artif. Intell.*, 18, 186–201.
- Rodríguez, S., De Paz, J. F., Villarrubia, G., Zato, C., Bajo, J., & Corchado, J. M. (2015). Multi-agent information fusion system to manage data from a wsn in a residential home. *Information Fusion*, 23, 43–57.
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M., & Rigol-Sánchez, J. P. (2012). An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS journal of photogrammetry and remote sensing*, 67, 93–104.
- Román, J. A., Rodríguez, S., & Prieta, F. d. l. (2016). Improving the distribution of services in mas. En *International conference on practical applications of agents and multi-agent systems* (pp. 37–46).
- Ruiz Pérez, G. (2019). *Accidentes de trabajo mortales en España: Una visión histórica-estructural* (B.S. thesis).
- Sabatini, A. M., Ligorio, G., Mannini, A., Genovese, V., & Pinna, L. (2015). Prior-to-and post-impact fall detection using inertial and barometric altimeter measurements. *IEEE transactions on neural systems and rehabilitation engineering*, 24(7), 774–783.
- Salih, A., & Abraham, A. (2013). A review of ambient intelligence assisted healthcare monitoring. *International Journal of Computer Information Systems and Industrial Management (IJCISIM)*, 5, 741–750.
- Sánchez, M., Rodriguez, C., Manuel, J., & et al. (2020). Smart protective protection equipment for an accessible work environment and occupational hazard prevention. En *2020 10th international conference on cloud computing, data science & engineering (confluence)* (pp. 581–585).

- Sánchez, S., Rodríguez, S., Prieta, F. D. I., Paz, J. F. D., & Bajo, J. (2015). Multi-agent system for tracking and classification of moving objects. En *Distributed computing and artificial intelligence, 12th international conference* (pp. 63–74).
- Sánchez, S. M. (2019). Electronic textiles for intelligent prevention of occupational hazards. En *International symposium on distributed computing and artificial intelligence* (pp. 217–220).
- Sánchez, S. M., Lecumberri, F., Sati, V., Arora, A., Shoeibi, N., Rodríguez, S., & Rodríguez, J. M. C. (2020). Edge computing driven smart personal protective system deployed on nvidia jetson and integrated with ros. En *International conference on practical applications of agents and multi-agent systems* (pp. 385–393).
- Sánchez, S. M., Vara, R. C., Criado, F. J. G., González, S. R., Tejedor, J. P., & Corchado, J. M. (2019). Smart ppe and cpe platform for electric industry workforce. En *International workshop on soft computing models in industrial and environmental applications* (pp. 422–431).
- San Románn Lana, I., & et al. (2019). Sistema context-aware de videovigilancia inteligente bajo el paradigma edge-computing.
- Sarkar, S., & Maiti, J. (2020). Machine learning in occupational accident analysis: A review using science mapping approach with citation network analysis. *Safety science*, 131, 104900.
- Sarma, K. K. (2009). Neural network based feature extraction for assamese character and numeral recognition. *International Journal of Artificial Intelligence*, 2(S09), 37–56.
- Sati, V., Sánchez, S. M., Shoeibi, N., Arora, A., & Corchado, J. M. (2020). Face detection and recognition, face emotion recognition through nvidia jetson nano. En *International symposium on ambient intelligence* (pp. 177–185).
- Satyanarayanan, M. (2017). The emergence of edge computing. *Computer*, 50(1), 30–39.
- Scheinder, E. (2014). *Eu-osha activities on work-related diseases and their link to emerging risks at work*. Retrieved from EU-OSHA.
- Schneegass, S., Hassib, M., Zhou, B., Cheng, J., Seoane, F., Amft, O., ... Schmidt, A. (2015). Simpleskin: towards multipurpose smart garments. En *Adjunct proceedings of the 2015 acm international joint conference on pervasive and ubiquitous computing and proceedings of the 2015 acm international symposium*

- on wearable computers* (pp. 241–244).
- Schneegass, S., & Voit, A. (2016). Gesturesleeve: using touch sensitive fabrics for gestural input on the forearm for controlling smartwatches. En *Proceedings of the 2016 ACM international symposium on wearable computers* (pp. 108–115).
- Scott, R. A. (2005). *Textiles for protection*. Elsevier.
- Sendra, S., Parra, L., Lloret, J., & Tomás, J. (2018). Smart system for children's chronic illness monitoring. *Information Fusion*, 40, 76–86.
- Shahnavaz, H. (1987). Workplace injuries in the developing countries. *Ergonomics*, 30(2), 397–404.
- Sharma, A., Kumar, A., & Bhardawaj, A. (2014). A review of ambient intelligence system: bringing intelligence to environments. *International Journal of Information & Computation Technology*, 4(9), 879–884.
- Shawish, A., & Salama, M. (2014). Cloud computing: paradigms and technologies. En *Inter-cooperative collective intelligence: Techniques and applications* (pp. 39–67). Springer.
- Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge computing: Vision and challenges. *IEEE internet of things journal*, 3(5), 637–646.
- Shi, W., & Dustdar, S. (2016). The promise of edge computing. *Computer*, 49(5), 78–81.
- Shin, D., Shin, D., & Shin, D. (2014). Ubiquitous health management system with watch-type monitoring device for dementia patients. *Journal of Applied Mathematics*, 2014.
- Shin, D.-M., Shin, D., & Shin, D. (2013). Smart watch and monitoring system for dementia patients. En *International conference on grid and pervasive computing* (pp. 577–584).
- Shine, L., & CV, J. (2020). Automated detection of helmet on motorcyclists from traffic surveillance videos: a comparative analysis using hand-crafted features and cnn. *Multimedia Tools and Applications*, 79(19), 14179–14199.
- Shyr, T.-W., Shie, J.-W., Jiang, C.-H., & Li, J.-J. (2014). A textile-based wearable sensing device designed for monitoring the flexion angle of elbow and knee movements. *Sensors*, 14(3), 4050–4059.
- Silva, T. C., & Zhao, L. (2016). *Machine learning in complex networks* (Vol. 1). Springer.
- Singh, D., Merdivan, E., Psychoula, I., Kropf, J., Hanke, S., Geist, M., & Holzinger, A. (2017). Human activity recognition using recurrent neural networks.

- En *International cross-domain conference for machine learning and knowledge extraction* (pp. 267–274).
- Sittón, I., & Rodríguez, S. (2017). Pattern extraction for the design of predictive models in industry 4.0. En *International conference on practical applications of agents and multi-agent systems* (pp. 258–261).
- Sittón-Candanedo, I., Alonso, R. S., Corchado, J. M., Rodríguez-González, S., & Casado-Vara, R. (2019). A review of edge computing reference architectures and a new global edge proposal. *Future Generation Computer Systems*, 99, 278–294.
- Sittón-Candanedo, I., Alonso, R. S., García, Ó., Gil, A. B., & Rodríguez-González, S. (2019). A review on edge computing in smart energy by means of a systematic mapping study. *Electronics*, 9(1), 48.
- Sittón-Candanedo, I., Alonso, R. S., García, Ó., Muñoz, L., & Rodríguez-González, S. (2019). Edge computing, iot and social computing in smart energy scenarios. *Sensors*, 19(15), 3353.
- Smitha, M. W., Kirk, K. A., Oestenstad, K. R., Brown, K. C., & Lee, S.-D. (2001). Effect of state workplace safety laws on occupational injury rates. *Journal of occupational and environmental medicine*, 1001–1010.
- Stafford, R. J., & Hazle, J. D. (2006). Magnetic resonance temperature imaging for focused ultrasound surgery: a review. *Topics in Magnetic Resonance Imaging*, 17(3), 153–163.
- Starner, T., Mann, S., Rhodes, B., Healey, J., Russell, K. B., Levine, J., & Pentland, A. (1995). Wearable computing and augmented reality. *The Media Laboratory, Massachusetts Institute of Technology, Cambridge, MA, MIT Media Lab Vision and Modeling Group Technical Report*, 355.
- Stephanidis, C., Antona, M., & Ntoa, S. (2021). Human factors in ambient intelligence environments. *Handbook of Human Factors and Ergonomics*, 1058–1084.
- Stephenson, M., Amarasinghe, S., Martin, M., & O'Reilly, U.-M. (2003). Meta optimization: Improving compiler heuristics with machine learning. *ACM sigplan notices*, 38(5), 77–90.
- Sun, X., & Ansari, N. (2016). Edgeiot: Mobile edge computing for the internet of things. *IEEE Communications Magazine*, 54(12), 22–29.
- Sundermeyer, M., Schlüter, R., & Ney, H. (2012). Lstm neural networks for language processing. En *Interspeech* (Vol. 2012, pp. 194–197).

- Sutherland, I. E. (1968). A head-mounted three dimensional display. En *Proceedings of the december 9-11, 1968, fall joint computer conference, part i* (pp. 757–764).
- Syduzzaman, M., Patwary, S. U., Farhana, K., & Ahmed, S. (2015). Smart textiles and nano-technology: a general overview. *J. Text. Sci. Eng.*, 5(1).
- Tao, X. (2005). *Wearable electronics and photonics*. Elsevier.
- Tao, X., & et al. (2015). *Handbook of smart textiles*. Springer.
- Tapia, D. I., Fraile, J. A., Rodríguez, S., Alonso, R. S., & Corchado, J. M. (2013). Integrating hardware agents into an enhanced multi-agent architecture for ambient intelligence systems. *Information Sciences*, 222, 47–65.
- Tapia, E. M., Intille, S. S., & Larson, K. (2004). Activity recognition in the home using simple and ubiquitous sensors. En *International conference on pervasive computing* (pp. 158–175).
- Tarrahi, M., & Shadravan, A. (2016). Intelligent hse big data analytics platform promotes occupational safety. En *Spe annual technical conference and exhibition*.
- Tatić, D., & Tešić, B. (2017). The application of augmented reality technologies for the improvement of occupational safety in an industrial environment. *Computers in Industry*, 85, 1–10.
- Teizer, J., Cheng, T., & Fang, Y. (2013). Location tracking and data visualization technology to advance construction ironworkers' education and training in safety and productivity. *Automation in Construction*, 35, 53–68.
- Thorp, E. O. (1998). The invention of the first wearable computer. En *Digest of papers. second international symposium on wearable computers (cat. no. 98ex215)* (pp. 4–8).
- Tulshyan, V., Sharma, D., & Mittal, M. (2020). An eye on the future of covid-19: Prediction of likely positive cases and fatality in india over a 30-day horizon using the prophet model. *Disaster Medicine and Public Health Preparedness*, 1–7.
- Tüzün, E., Tekinerdogan, B., Macit, Y., & İnce, K. (2019). Adopting integrated application lifecycle management within a large-scale software company: An action research approach. *Journal of Systems and Software*, 149, 63–82.
- Van den Oord, A., Dieleman, S., & Schrauwen, B. (2013). Deep content-based music recommendation. *Advances in neural information processing systems*, 26.
- Varian, H., & et al. (2018). Artificial intelligence, economics, and industrial organization. *The economics of artificial intelligence: an agenda*, 24.

- Vaughn Jr, R. B., Henning, R., & Fox, K. (2002). An empirical study of industrial security-engineering practices. *Journal of Systems and software*, 61(3), 225–232.
- Vida, M. N. M., Morales, Á. J. G., Soria, J. V., Fernández, R. V., Prieto, A. M., Villanueva, A. J. M., ... Aznarte, M. T. D. (2006). *Manual para la formación en prevención de riesgos laborales. programa formacitivo para el desempeño de las funciones de nivel básico*. Lex Nova.
- Wahab, L., & Jiang, H. (2019). A comparative study on machine learning based algorithms for prediction of motorcycle crash severity. *PLoS one*, 14(4), e0214966.
- Wile, D. J., Ranawaya, R., & Kiss, Z. H. (2014). Smart watch accelerometry for analysis and diagnosis of tremor. *Journal of neuroscience methods*, 230, 1–4.
- Williams, G., Doughty, K., Cameron, K., & Bradley, D. (1998). A smart fall and activity monitor for telecare applications. En *Proceedings of the 20th annual international conference of the ieee engineering in medicine and biology society. vol. 20 biomedical engineering towards the year 2000 and beyond (cat. no. 98ch36286)* (Vol. 3, pp. 1151–1154).
- Wu, G., & Xue, S. (2008). Portable preimpact fall detector with inertial sensors. *IEEE Transactions on neural systems and Rehabilitation Engineering*, 16(2), 178–183.
- Wu, W., Dasgupta, S., Ramirez, E. E., Peterson, C., Norman, G. J., & et al. (2012). Classification accuracies of physical activities using smartphone motion sensors. *Journal of medical Internet research*, 14(5), e2208.
- Xian, W., Tarrío Alonso, P., Bernardos Barbolla, A. M., Metola Moreno, E., & Casar Corredora, J. R. (2012). User-independent accelerometer-based gesture recognition for mobile devices. *Advances in Distributed Computing and Artificial Intelligence Journal*, 1(3), 11–25.
- Xiaoli, X., Yunbo, Z., & Guoxin, W. (2011). Design of intelligent internet of things for equipment maintenance. En *2011 fourth international conference on intelligent computation technology and automation* (Vol. 2, pp. 509–511).
- Yao, B., Zhou, Z., Xu, W., Fang, Y., Shao, L., Wang, Q., & Liu, A. (2015). Service-oriented predictive maintenance for large scale machines based on perception big data. En *International manufacturing science and engineering conference* (Vol. 56833, p. V002T04A015).
- Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd.
- Yogameena, B., Menaka, K., & Perumaal, S. S. (2019). Deep learning-based helmet wear analysis of a motorcycle rider for intelligent surveillance system. *IET Intelligent*

- Transport Systems*, 13(7), 1190–1198.
- Yu, W., Liang, F., He, X., Hatcher, W. G., Lu, C., Lin, J., & Yang, X. (2017). A survey on the edge computing for the internet of things. *IEEE access*, 6, 6900–6919.
- Zampella, F., Khider, M., Robertson, P., & Jiménez, A. (2012). Unscented kalman filter and magnetic angular rate update (maru) for an improved pedestrian dead-reckoning. En *Proceedings of the 2012 ieee/ion position, location and navigation symposium* (pp. 129–139).
- Zhang, S., & Zhang, H. (2012). A review of wireless sensor networks and its applications. En *2012 ieee international conference on automation and logistics* (pp. 386–389).
- Zhou, Y., Jing, L., Wang, J., & Cheng, Z. (2012). Analysis and selection of features for gesture recognition based on a micro wearable device. *International Journal of Advanced Computer Science & Applications*, 3(1).
- Zhu, C., & Sheng, W. (2009). Human daily activity recognition in robot-assisted living using multi-sensor fusion. En *2009 ieee international conference on robotics and automation* (pp. 2154–2159).
- Zhu, Y., Nayak, N. M., & Roy-Chowdhury, A. K. (2012). Context-aware activity recognition and anomaly detection in video. *IEEE Journal of Selected Topics in Signal Processing*, 7(1), 91–101.
- Zivkovic, Z. (2004). Improved adaptive gaussian mixture model for background subtraction. En *Proceedings of the 17th international conference on pattern recognition, 2004. icpr 2004.* (Vol. 2, pp. 28–31).
- Zong, B., Song, Q., Min, M. R., Cheng, W., Lumezanu, C., Cho, D., & Chen, H. (2018). Deep autoencoding gaussian mixture model for unsupervised anomaly detection. En *International conference on learning representations*.
- Zúñiga, A. H. (2003). *Seguridad e higiene industrial*. Editorial Limusa.

