

UNIVERSIDAD MIGUEL HERNÁNDEZ DE ELCHE
Programa de Doctorado en Tecnologías Industriales y de Telecomunicación



NUEVOS DISPOSITIVOS ELECTRÓNICOS Y
ALGORITMOS PARA LA MONITORIZACIÓN
AMBULATORIA DE PERSONAS CON TRASTORNO DEL
ESPECTRO DE AUTISMO

JOSÉ MARÍA VICENTE SAMPER

Director: JOSÉ MARÍA SABATER NAVARRO

Codirector: ERNESTO ÁVILA NAVARRO

Elche, Noviembre 2021

La presente Tesis Doctoral está sustentada por un compendio de trabajos previamente publicados en revistas de impacto, indexadas según el *Scimago Journal & Country Rank*. El cuerpo de dicha tesis queda constituido por los siguientes artículos, cuyas referencias bibliográficas completas se indican a continuación:

Vicente-Samper, J. M.; Ávila-Navarro, E. y Sabater-Navarro, J. M. (2020), «Data Acquisition Devices Towards a System for Monitoring Sensory Processing Disorders», *IEEE Access* **8**, págs. 183596-183605, DOI: [10.1109/ACCESS.2020.3029692](https://doi.org/10.1109/ACCESS.2020.3029692)

- Título de la revista: IEEE Access (ISSN: 2169-3536)
- Factor de impacto SJR (2020): 0,587
- Categoría: Engineering (miscellaneous), Cuartil Q1 (82/365).

Vicente-Samper, J. M.; Avila-Navarro, E.; Esteve, V. y Sabater-Navarro, J. M. (2021), «Intelligent Monitoring Platform to Evaluate the Overall State of People with Neurological Disorders», *Applied Sciences* **11**(6), DOI: [10.3390/app11062789](https://doi.org/10.3390/app11062789)

- Título de la revista: Applied Sciences(ISSN: 2076-3417)
- Factor de impacto SJR (2020): 0,435
- Categoría: Engineering (miscellaneous), Cuartil Q2 (110/365).



AUTORIZACIÓN DE PRESENTACIÓN DE TESIS DOCTORAL POR COMPENDIO DE PUBLICACIONES

Director: José María Sabater Navarro

Codirector: Ernesto Ávila Navarro

Título de la tesis: **Nuevos dispositivos electrónicos y algoritmos para la monitorización ambulatoria de personas con Trastorno del Espectro de Autismo**

Autor: José María Vicente Samper

Departamento de Ingeniería de Sistemas y Automática
Universidad Miguel Hernández de Elche

Los directores de la tesis reseñada certifican que ha sido realizada bajo su dirección por José María Vicente Samper en el Departamento de Ingeniería de Sistemas y Automática de la Universidad Miguel Hernández de Elche, y autorizo su presentación.

Elche, Noviembre 2021

José María Sabater Navarro

Ernesto Ávila Navarro



PROGRAMA DE DOCTORADO EN TECNOLOGÍAS INDUSTRIALES Y DE TELECOMUNICACIÓN

Dr. Óscar Reinoso García, Coordinador del Programa de Doctorado en Tecnologías Industriales y de Telecomunicación en la Universidad Miguel Hernández de Elche,

CERTIFICA

Que el trabajo realizado por D. José María Vicente Samper, titulado **Nuevos dispositivos electrónicos y algoritmos para la monitorización ambulatoria de personas con Trastorno del Espectro de Autismo**, ha sido dirigido por el Dr. José María Sabater Navarro y codirigido por el Dr. Ernesto Ávila Navarro, y se encuentra en condiciones de ser leído y defendido como Tesis Doctoral ante el correspondiente tribunal en la Universidad Miguel Hernández de Elche.

Lo que firmo para los efectos oportunos en

Elche, Noviembre 2021

Óscar Reinoso García

ABSTRACT

People with Autism Spectrum Disorder (ASD) show a great heterogeneity in their atypical sensory behaviours. Almost all people with ASD have a linked Sensory Processing Disorder that sometimes prevents them from organizing the information that the environment offers them through stimuli. This can cause problems in performing some daily life activities such as working, going to school or participating in social and entertainment events, which further difficulties the typical development of these people.

This Doctoral Thesis focuses on the development of a monitoring platform that helps to identify situations in which a person with ASD may be overwhelmed due to a saturation of stimuli received from the environment. The platform consists of multiple monitoring devices, both of the person's physiological signals and of stimuli from the environment. The second component of the platform is the use of machine learning applied to the records obtained from the monitoring systems.

The main results of this work have been published in two articles in the *Scimago Journal & Country Rank*. In the publication *Data Acquisition Devices Towards a System for Monitoring Sensory Processing Disorders*, the development of a physiological signal monitoring device specially designed for people with ASD is presented, as well as the development of a device for monitoring environmental conditions and an application for the analysis of environmental sound. All the information collected by the devices is organized and stored in a remote database. Finally, an experimentation is presented where the devices are validated and a task classifier is built from the signals provided by the system. On the other hand, the publication *Intelligent Monitoring Platform to Evaluate the Overall State of People with Neurological Disorders* presents the development of a device for monitoring visual stimuli as well as the design of a new improved physiological signal monitoring device. Finally, this publication also presents the use of the signals recorded with the platform developed for the generation of predictive models using machine learning techniques.

RESUMEN

Las personas con Trastorno del Espectro de Autismo (TEA) manifiestan una gran heterogeneidad en sus comportamientos sensoriales atípicos. Casi la totalidad de las personas que lo sufren tienen asociado un Trastorno del Procesamiento Sensorial que en ocasiones les impide ordenar la información que el entorno les ofrece a través de estímulos. Esta situación puede provocar problemas para realizar algunas actividades de la vida diaria como trabajar, asistir al colegio o participar en eventos sociales y recreativos, hecho que dificulta todavía más el desarrollo normal de estas personas.

La presente Tesis Doctoral se centra en el desarrollo de una plataforma de monitorización que ayude a identificar las situaciones en las que una persona con TEA se pueda ver abrumada debido a una saturación de estímulos recibidos desde el entorno. La plataforma está formada por múltiples dispositivos de monitorización, tanto de las señales fisiológicas de la persona como de los estímulos del entorno. El segundo componente de la plataforma es el uso del aprendizaje supervisado aplicado a los registros obtenidos con los sistemas de monitorización.

Los principales resultados de esta tesis se han publicado en dos artículos en revistas indexadas en el *Scimago Journal & Country Rank*. En la publicación *Data Acquisition Devices Towards a System for Monitoring Sensory Processing Disorders* se presenta el desarrollo de un dispositivo de monitorización de señales fisiológicas especialmente diseñado para personas con TEA, así como también se presenta el desarrollo de un dispositivo de monitorización de las condiciones ambientales y una aplicación que se encarga de analizar el sonido ambiente. Toda la información recolectada por los dispositivos se almacena organizada en una base de datos remota. En última instancia se presenta una experimentación donde se validan los dispositivos y se construye un clasificador de tareas a partir de las señales proporcionadas por el sistema. Por otro lado, en la publicación *Intelligent Monitoring Platform to Evaluate the Overall State of People with Neurological Disorders* se presenta el desarrollo de un dispositivo para la monitorización de estímulos visuales así como el diseño de un nuevo dispositivo de monitorización de señales fisiológicas mejorado. Finalmente, en esta publicación también se expone el uso de las señales registradas con la plataforma desarrollada para la construcción de modelos predictivos utilizando técnicas de aprendizaje automatizado.

AGRADECIMIENTOS

En primer lugar, quiero agradecer a mis directores de tesis la confianza y el apoyo que me han dado todo este tiempo. Siempre piensan en lo mejor para mi y me han proporcionado todo lo necesario para desarrollar mi trabajo.

También quiero dar las gracias a todos los compañeros de laboratorio con los que tantos momentos he compartido. Han sido muchas horas debatiendo ideas y solucionando problemas, pero con buena música de fondo.

Por supuesto, debo darle las gracias a mi familia porque sin ellos no habría llegado hasta aquí. Gracias por darme todo en la vida y haberme dado la oportunidad de crecer académicamente a lo largo de los años.

Como no, también quiero dar las gracias a esa otra familia que se elige, a mis amigos. Porque con vosotros he ido creciendo como persona y he aprendido de todas las situaciones que se nos han presentado. Sé que siempre podré contar con vosotros.

Quiero darle las gracias además a los compañeros del Creo Lab de la Università Campus Bio-Medico di Roma por la acogida que me dieron en su grupo de trabajo durante los meses de estancia y por haber compartido buenos momentos conmigo.

Por último, quiero agradecerle todo su apoyo a esa persona que apareció en mi vida y que desde entonces todo ha cambiado para mí. Gracias Auro. Gracias por entender mi pasión por lo que hago y todo el tiempo que le dedico. Sé que no es un viaje fácil pero quiero disfrutar del camino contigo.

Este trabajo ha sido financiado dentro del Programa para el apoyo a personas investigadoras con talento "Plan GenT" a través de la subvención para contratación de personal con código FDEGENT/2018/015, concedida por la Conselleria d'Educació, Investigació, Cultura i Esport de la Generalitat Valenciana.



ÍNDICE GENERAL

1	INTRODUCCIÓN	1
1.1	El Trastorno del Espectro de Autismo	1
1.1.1	Influencia del Trastorno del Procesamiento Sensorial	5
1.2	Hipótesis y aportaciones del trabajo	6
1.3	Motivación del trabajo	7
1.4	Estructura de la tesis	12
1.5	Publicaciones	13
2	ESTADO DEL ARTE	15
2.1	Aportaciones clínicas al Trastorno del Espectro de Autismo	15
2.2	Sistemas ambulatorios de monitorización de bioseñales	17
2.2.1	Dispositivos diseñados para usuarios con características especiales	18
2.3	Sistemas inteligentes para la medición del entorno	19
2.4	Inteligencia artificial en la medicina	20
3	DISPOSITIVO DE MONITORIZACIÓN PERSONAL	25
3.1	Requisitos de diseño del dispositivo	25
3.2	Sensores integrados en el dispositivo	26
3.2.1	Sensor de temperatura corporal	26
3.2.2	Sensor de frecuencia cardíaca	29
3.2.3	Sensor de actividad motora	32
3.3	Control y comunicación del dispositivo	35
3.4	Gestión de la alimentación	36
3.4.1	Accesorio para la carga de la batería	38
3.5	Fabricación y montaje del dispositivo	39
3.6	Conclusiones del capítulo	41
4	DISPOSITIVOS DE MONITORIZACIÓN DEL ENTORNO	43
4.1	Dispositivo de adquisición de las condiciones del entorno	43
4.1.1	Requisitos de diseño del dispositivo	44
4.1.2	Sensores integrados en el dispositivo	44
4.1.2.1	Sensor de temperatura ambiente y humedad relativa	45
4.1.2.2	Sensor de presión atmosférica	46
4.1.2.3	Sensor de luminosidad	47

4.1.3	Control y comunicación del dispositivo	49
4.1.4	Gestión de la alimentación	50
4.1.5	Fabricación y montaje del dispositivo	50
4.2	Dispositivo de adquisición de estímulos visuales	52
4.2.1	Requisitos del dispositivo	53
4.2.2	Configuración de hardware y software	54
4.2.3	Detección y cuantificación de personas	55
4.2.4	Cuantificación del flujo óptico	56
4.2.5	Montaje y alimentación del dispositivo	58
4.3	Análisis del espectro de sonido	59
4.4	Conclusiones del capítulo	61
5	GESTIÓN DEL SISTEMA Y ALMACENAMIENTO DE LA INFORMACIÓN	63
5.1	Dispositivo de gestión del sistema	63
5.1.1	Interfaz gráfica de usuario	65
5.1.2	Comunicación dispositivo central - base de datos	66
5.1.2.1	Organización de las variables en documentos <i>BSON</i>	67
5.2	Almacenamiento de la información	70
5.2.1	Estructura de almacenamiento	71
5.2.2	Acceso a la información y generación de gráficos en tiempo real	72
5.3	Conclusiones del capítulo	73
6	INGENIERÍA DE ATRIBUTOS Y GENERACIÓN DE MODELOS PREDICTIVOS	75
6.1	Ingeniería de atributos	75
6.1.1	Procesado de las señales y creación de atributos	76
6.1.2	Generación del dataset para el entrenamiento del modelo	81
6.2	Entrenamiento y generación de modelos predictivos	82
6.2.1	Aprendizaje automatizado	83
6.2.1.1	Aprendizaje supervisado	83
6.2.1.2	Aprendizaje no supervisado	87
6.2.1.3	Aprendizaje por refuerzo mediante aprendizaje no supervisado	92
6.2.1.4	Aprendizaje semisupervisado	93
6.2.2	Selección de algoritmo y entrenamiento de un modelo predictivo	94
6.2.2.1	Métricas de evaluación de resultados	95
6.2.2.2	Hiperparámetros del entrenamiento	98
6.2.2.3	Acondicionamiento del dataset	99
6.3	Conclusiones del capítulo	100

7	EXPERIMENTACIÓN EN ENTORNO CLÍNICO CON USUARIOS CON TRASTORNO DEL ESPECTRO DE AUTISMO	101
7.1	Implantación de la plataforma desarrollada en un entorno clínico	101
7.1.1	Configuración del entorno clínico	103
7.1.2	Protocolo para la adquisición de datos	105
7.1.3	Evolución de la experimentación durante las sesiones	106
7.2	Resultados de la experimentación	107
7.2.1	Procesado de las señales y generación del conjunto de datos . . .	108
7.2.2	Uso de algoritmos de AA para la extracción de información . . .	111
7.3	Aplicación para la divulgación dinámica de resultados	117
7.4	Conclusiones del capítulo	120
8	ALGORITMO PARA LA RECONSTRUCCIÓN DE LA FRECUENCIA CARDÍACA EN TAREAS CON ARTEFACTOS DE MOVIMIENTO MEDIANTE APRENDIZAJE AUTOMATIZADO	123
8.1	Relevancia de la frecuencia cardíaca y problemática de la señal de PPG	123
8.1.1	Métodos para la eliminación de artefactos de movimiento en la señal de PPG	126
8.1.1.1	Uso de los métodos existentes en el sistema desarrollado	127
8.2	Algoritmo de reconstrucción de la frecuencia cardíaca	130
8.2.1	Protocolo para la adquisición de señales con usuarios	131
8.2.2	Entrenamiento de un modelo de clasificación de actividades . . .	134
8.2.3	Entrenamiento de un modelo de estimación de la frecuencia cardíaca	137
8.2.4	Arquitectura del algoritmo implementado	141
8.3	Resultados de la reconstrucción de la FC utilizando el algoritmo	142
8.4	Conclusiones del capítulo	148
9	CONCLUSIONES	151
9.1	Conclusión	151
9.2	Trabajos futuros	153
10	CONCLUSIONS	155
10.1	Conclusion	155
10.2	Future work	157
A	CONTRIBUCIONES PRINCIPALES	159
	BIBLIOGRAFÍA	187

ÍNDICE DE FIGURAS

Figura 1.1	Esquema conceptual de la arquitectura de trabajo en la plataforma desarrollada.	8
Figura 3.1	Gráfica de la evolución de la temperatura corporal de un usuario medida con el sensor durante una sesión de prueba.	28
Figura 3.2	Recreación de la medida de la temperatura de la piel T_S en el usuario.	29
Figura 3.3	Recreación del posicionamiento y medida del sensor de Fotopleetismografía (PPG) en el usuario. Incluye un esquema con las principales componentes que forman la señal de PPG.	31
Figura 3.4	Las diferentes etapas del procesado a una ventana de la señal de PPG.	33
Figura 3.5	Gráficas de la evolución de las señales de aceleración y giroscopio de un usuario medida con el sensor durante una sesión de prueba.	34
Figura 3.6	Recreación del posicionamiento del sensor de Actividad motora (AM) en el usuario.	35
Figura 3.7	Flujo de trabajo del microcontrolador que controla el dispositivo de monitorización de bioseñales.	37
Figura 3.8	Imagen virtual del dispositivo de monitorización ambulatoria de bioseñales donde se aprecia el puerto USB Type-A impreso para la carga de la batería del dispositivo.	38
Figura 3.9	(a) Imagen virtual del accesorio para la carga de la batería. (b) Fotografía real del accesorio para la carga de la batería del dispositivo de monitorización de bioseñales.	39
Figura 3.10	Geometría de corte de la carcasa para el dispositivo de monitorización de bioseñales.	40
Figura 3.11	(a) Fotografía de un dispositivo de monitorización ambulatoria de bioseñales finalizado. (b) Fotografía del emplazamiento del dispositivo de monitorización en la muñeca del usuario.	41

Figura 4.1	Gráficas de la evolución de la temperatura ambiente y la humedad relativa medidas con el sensor durante una sesión de prueba.	46
Figura 4.2	Gráfica de la evolución de la presión atmosférica medida con el sensor durante una sesión de prueba.	47
Figura 4.3	Gráfica de la evolución de la luminosidad de la estancia medida con el sensor durante una sesión de prueba.	48
Figura 4.4	Flujo de trabajo del microcontrolador que controla el dispositivo de adquisición de condiciones del entorno.	51
Figura 4.5	Imagen virtual de la placa electrónica que forma el dispositivo de adquisición de condiciones del entorno.	52
Figura 4.6	Fotografías de un dispositivo de adquisición de condiciones del entorno finalizado.	53
Figura 4.7	Arquitectura de redes de <i>YoloV5</i>	55
Figura 4.8	Captura de pantalla de un fotograma analizado por el modelo de detección de personas.	57
Figura 4.9	Gráfica de la evolución del flujo óptico medido durante una sesión de prueba.	58
Figura 4.10	Fotografía real del dispositivo de monitorización de estímulos visuales.	59
Figura 4.11	Gráfica del análisis del espectro de sonido medido por el sensor durante una sesión de prueba.	62
Figura 5.1	Captura de pantalla de la interfaz gráfica de usuario de la aplicación <i>Android</i> diseñada para uso doméstico.	66
Figura 5.2	Mapa conceptual de la arquitectura de almacenamiento de la información.	71
Figura 5.3	Captura de pantalla de un panel de instrumentación generado con las herramientas de <i>MongoDB</i> para mostrar los valores de las variables medidas con el dispositivo de adquisición de las condiciones de entorno durante la realización de una sesión de prueba.	72
Figura 6.1	Esquema dataset.	82
Figura 6.2	Ejemplo de matriz de confusión para un problema binario.	96
Figura 6.3	Diagrama de la división del conjunto de datos y del proceso de validación cruzada.	100

Figura 7.1	Fotografías de la sala habilitada en la Clínica Universitaria para la realización de la experimentación.	104
Figura 7.2	Algunos de los atributos generados con las señales obtenidas durante la experimentación. Se representan los valores normalizados para los diferentes grupos de actividades mediante el valor de la mediana y la caja de error cuyos extremos representan el primer y tercer cuartil.	112
Figura 7.3	Distribución en el espacio de las etiquetas de grupo de tarea utilizando los dos primeros vectores resultado de aplicar el algoritmo Principal Component Analysis (PCA).	114
Figura 7.4	Distribución en el espacio de las etiquetas de grupo de tarea utilizando los dos primeros vectores resultado de aplicar diferentes algoritmos de reducción de la dimensionalidad. (a) Incremental PCA. (b) PCA disperso. (c) Proyección Gaussiana Aleatoria. (d) Descomposición en Valores Singulares.	115
Figura 7.5	(a) Gráfica resultado de la inercia del algoritmo <i>K-Means</i> según el número de clústeres utilizados en el entrenamiento. (b) Gráfica de la exactitud global del modelo en función del número de clústeres utilizado.	116
Figura 7.6	Imagen de la página inicial de la aplicación web desarrollada para consultar los registros y resultados de la experimentación.	118
Figura 7.7	(a) Imagen de la página de "Usuarios" donde se muestra el listado de los usuarios disponibles. (b) Imagen de la página "Usuarios" donde se muestra el listado de las sesiones de uno de los usuarios disponibles.	119
Figura 7.8	(a) Imagen de la aplicación web donde se muestran los registros de una sesión en modo <i>Gráficas</i> . (b) Imagen de la aplicación web donde se muestran los registros de una sesión en modo <i>Tablas</i> . (c) Imagen de la aplicación web donde se muestran resultados de una sesión en la pestaña <i>Resultados</i>	121
Figura 8.1	Gráfica de la señal de PPG durante una sesión de prueba.	124
Figura 8.2	Gráficas resultado de la aplicación del filtrado a la señal original de PPG en períodos con dos actividades diferentes.	125
Figura 8.3	Modelo simplificado de los artefactos de movimiento en la señal de PPG.	129

Figura 8.4	Señal de la FC reconstruida aplicando una solución de filtro adaptativo a partir de las señales de aceleración.	130
Figura 8.5	Diagrama de trabajo para el registro de datos utilizando el <i>BioHarness</i> en paralelo al dispositivo de monitorización de señales fisiológicas.	132
Figura 8.6	Fotografías de usuarios realizando las diferentes actividades propuestas para el registro de datos.	133
Figura 8.7	Resultado de aplicar el algoritmo NCA a los atributos del conjunto de datos con los pesos de cada atributo.	135
Figura 8.8	Matriz de confusión resultado de la evaluación del modelo de clasificación final.	137
Figura 8.9	Resultado de aplicar el algoritmo ReliefF a los atributos del conjunto de datos con los pesos de cada atributo.	138
Figura 8.10	Representación gráfica de los procesos del algoritmo implementado.	141
Figura 8.11	Resultado de la reconstrucción de la Frecuencia cardíaca (FC) en un usuario participante en el entrenamiento y con alta confianza en la FC del <i>BioHarness</i>	143
Figura 8.12	Resultado de la reconstrucción de la FC en un usuario participante en el entrenamiento y con baja confianza en la FC del <i>BioHarness</i>	144
Figura 8.13	Resultado de la reconstrucción de la FC en un nuevo usuario con el rango de valores de la FC anormalmente bajos.	145
Figura 8.14	Resultado de la reconstrucción de la FC en un nuevo usuario con el rango de valores de la FC típico.	146

ÍNDICE DE TABLAS

Tabla 1.1	Parámetros estudiados para el sistema ambulatorio de monitorización.	10
Tabla 1.2	Principales factores de las variables educacionales y biológicas.	11
Tabla 4.1	División de las bandas de Octavas.	61

Tabla 6.1	Codificación <i>one-hot</i> para la frecuencia dominante en el análisis del espectro de sonido.	79
Tabla 6.2	Codificación <i>one-hot</i> para la cantidad de personas en el entorno del usuario.	80
Tabla 7.1	Informe resumen de una sesión llevada a cabo con un usuario en la clínica.	106
Tabla 7.2	Resumen global de las variables en los registros tomados durante las sesiones en clínica del usuario descrito.	108
Tabla 7.3	Listado de las actividades desarrolladas por el usuario durante las sesiones de la experimentación, clasificadas en cuatro grupos según el nivel de estímulo.	110
Tabla 7.4	Varianza de los datos originales capturada por diferente número de <i>PCA</i>	113
Tabla 7.5	Resultados de la exactitud individual de cada clúster con el algoritmo <i>K-Means</i>	114
Tabla 7.6	Fragmento de la matriz resultado del dendograma generado por el algoritmo de clustering jerárquico.	117
Tabla 7.7	Resultados de la exactitud individual de cada clúster con el algoritmo de clustering jerárquico.	117
Tabla 8.1	Lista de las actividades desarrolladas durante el registro de datos.	133
Tabla 8.2	Resultados del entrenamiento de modelos para la clasificación de la tarea en desarrollo.	136
Tabla 8.3	Resultados del entrenamiento de modelos para la estimación de la frecuencia cardíaca.	139
Tabla 8.4	Tabla de resultados de la sesión de un usuario con la cofianza de la señal de la <i>FC</i> del <i>BioHarness</i> alta.	147
Tabla 8.5	Tabla de resultados de la sesión de un usuario con la cofianza de la señal de la <i>FC</i> del <i>BioHarness</i> baja.	147
Tabla 8.6	Tabla de resultados de la sesión de un usuario nuevo con el rango de valores de la <i>FC</i> anormalmente bajos.	147
Tabla 8.7	Tabla de resultados de la sesión de un usuario nuevo con el rango de valores de la <i>FC</i> típico.	147

ACRÓNIMOS

AA	Aprendizaje Automatizado
ACA	Análisis Conductual Aplicado
ADOS	Autism Diagnostic Observation Schedule
AM	Actividad motora
AVD	Actividades de la Vida Diaria
BLE	Bluetooth Low Energy
CI	Cociente intelectual
DSM-V	Manual Diagnóstico y Estadístico de los Trastornos Mentales - 5ª edición
ECG	Electrocardiograma
EVA	Etilvinilacetato
FC	Frecuencia cardíaca
FDA	Food and Drug Administration
FFT	Transformada rápida de Fourier
FIR	Respuesta Infinita a Impulso
IA	Inteligencia Artificial
ICIT	Intervención Conductual Intensiva Temprana
IMU	Unidad de Medida Inercial
KNN	K-Nearest Neighbors
NCA	Neighborhood Component Analysis
OMS	Organización Mundial de la Salud
PCA	Principal Component Analysis
PPG	Fotopleletismografía
PPM	Pulsaciones Por Minuto
RMSE	Root Mean Square Error
RTOS	Sistema Operativo en Tiempo Real
STAT	Screening Tool for Autism in Toddlers and Young Children
SVM	Support Vector Machine
TA	Tecnologías Asistenciales
TCC	Terapia Cognitivo-Conductual
TDAH	Trastorno por Déficit de Atención e Hiperactividad
TDI	Trastorno Desintegrativo Infantil

TEA Trastorno del Espectro de Autismo
TPS Trastorno del Procesamiento Sensorial

INTRODUCCIÓN

1.1 EL TRASTORNO DEL ESPECTRO DE AUTISMO

El Trastorno del Espectro de Autismo (TEA) es una afección compleja del desarrollo que afecta a la interacción social, la comunicación verbal y no verbal, y puede provocar un comportamiento limitado o repetitivo (Lord; Elsabbagh et al., 2018). Los efectos del TEA y la severidad de los síntomas son diferentes en cada persona que lo padece.

De acuerdo con la Organización Mundial de la Salud (OMS), actualmente uno de cada 160 niños en el mundo es diagnosticado con TEA (Organization, 2021; Elsabbagh et al., 2012). Esto representa una aproximación, dado que la prevalencia del TEA en muchos países de ingresos bajos es desconocida. Se desconoce la causa de este trastorno, que está presente en todas las razas, etnias y grupos socioeconómicos. Sin embargo, se estima que hay entre cuatro y cinco veces mayor probabilidad de sufrirlo entre el sexo masculino que entre el femenino (Dworzynski et al., 2012; Rutter, 2005). Pero en los últimos años estos datos están siendo cuestionados debido al aumento de casos detectados en niñas y mujeres (Gould y Ashton-Smith, 2011; Gould, 2017). Por lo tanto, esto hace plantear que el TEA tiene mayor riesgo de pasar desapercibido en el género femenino y esto dificulta todavía más su diagnóstico.

El sueño, la falta de atención o el comportamiento son algunas de las afecciones más comunes en las personas con desórdenes neurocognitivos como el TEA. Además, entre un 30 % y un 50 % de las personas con TEA tienen asociada una discapacidad intelectual (Cociente intelectual (CI) <70) (Christensen et al., 2016). Por lo tanto, estos problemas no hacen más que empeorar el desarrollo de las personas que lo sufren. No existe a día de hoy un medicamento para tratar el TEA. Sin embargo, las personas que lo padecen hacen un uso intensivo de la medicación para mitigar problemas derivados del trastorno, como el insomnio, la hiperactividad o problemas físicos originados por malas praxis motoras o la epilepsia. Esta medicación en ocasiones contribuye a agravar los problemas de desarrollo de estas personas causándoles problemas de comportamiento.

Las principales características de las personas con TEA se pueden agrupar en dos grandes grupos (*Diagnostic and statistical manual of mental disorders (5th ed.) 2013*):

- **Problemas de interacción social y de comunicación:** Este grupo incluye dificultades en una conversación normal de ida y vuelta, dificultades para intercambiar intereses o emociones, desafíos en la comprensión o en la respuesta a señales sociales como puede ser el contacto visual y las expresiones faciales, déficit en la comprensión de las relaciones (por ejemplo, problemas para hacer amigos), y otros relacionados.
- **Patrones de comportamiento, intereses o actividades limitadas y repetitivas:** Necesidad de batir las manos o caminar con los dedos de los pies, jugar con los juguetes de una manera poco común (por ejemplo, alinear coches o voltear objetos), hablar de una manera única (por ejemplo, usando patrones, tonos extraños o guiones de programas favoritos al hablar), tener la necesidad de seguir una rutina que sea predecible, mostrar un alto interés por actividades poco comunes a la edad, experimentar los aspectos sensoriales del mundo de una forma inusual o extrema (por ejemplo, indiferencia al dolor, oler o tocar excesivamente los objetos, una alta fascinación por las luces y el movimiento, sentirse abrumado por determinados ruidos, etc), y otros relacionados.

El TEA puede ser diagnosticado por diferentes profesionales (pediatras, psiquiatras o psicólogos). Existen diferentes instrumentos de diagnóstico estandarizados, por ejemplo, la herramienta de detección de autismo en niños pequeños (Screening Tool for Autism in Toddlers and Young Children (STAT), por sus siglas en inglés), que requiere de una observación de 20 minutos del niño (Mazurek et al., 2019). Otro instrumento disponible, el más investigado, es el programa de observación diagnóstica de autismo (Autism Diagnostic Observation Schedule (ADOS), por sus siglas en inglés), que requiere de una observación de 45 minutos realizada por un profesional cualificado, y se encuentra disponible en diferentes formatos para personas de diferentes niveles de lenguaje y edades (desde los 12 meses hasta la edad adulta) (Lord; Rutter et al., 1989). Estas herramientas permiten al clínico, en compañía del cuidador, observar y caracterizar los comportamientos particulares del individuo del que se sospecha que tiene TEA.

Un diagnóstico temprano es importante para comenzar un tratamiento adecuado y reducir los síntomas del TEA. Esto ayuda a mejorar la calidad de vida de las personas afectadas y a sus familias. Dado que no existe ninguna prueba médica para detectar el TEA, el diagnóstico se basa en la observación de cómo habla y actúa el niño en

comparación con otros niños de su edad. Los profesionales formados en la patología suelen diagnosticar el TEA hablando con el niño, haciendo preguntas a los padres y otros cuidadores, y haciendo uso de las herramientas previamente mencionadas. Aunque la mayoría de los niños con TEA son diagnosticados en la primera etapa del colegio, sigue habiendo otros que nunca han tenido un diagnóstico. Los diagnósticos posteriores, en edades de niños mayores o ya adolescentes suelen producirse en el contexto de problemas recurrentes como la ansiedad, la hiperactividad u otros trastornos del estado del ánimo, que podrían haber exacerbado o enmascarado el TEA. Un diagnóstico a estas edades necesita de las mismas observaciones clínicas específicas de la patología y de los informes de los cuidadores utilizados también en los niños pequeños. Sin embargo, también requieren atención a los trastornos psiquiátricos pertinentes que afecten a la persona. Por lo tanto, conseguir una detección temprana del trastorno es muy importante para evitar que los problemas en el desarrollo de la persona se agraven con el paso del tiempo, haciendo además más difícil el diagnóstico en el futuro.

Aunque las estimaciones varían, entre un 10 % y un 33 % de los adultos con TEA no emplean más que frases sencillas y tienen un coeficiente para la comunicación verbal y no verbal dentro del rango de la discapacidad intelectual (Happé et al., 2016). A pesar de ello, la mayoría de los adultos con TEA que tienen discapacidad intelectual pueden hablar a cierto nivel, son capaces de atender las necesidades básicas y tienen capacidad para trabajar, aunque requieren de un apoyo diario. Sin embargo, es difícil encontrar un empleo a pesar de que los logros educativos han mejorado con respecto a 20 años atrás (Howlin et al., 2013), aunque los empleos no suelen corresponderse con el nivel de educación adquirido.

La independencia es otro aspecto importante para una persona adulta. Sólo un 25 % de las personas con TEA con una inteligencia media viven solos en sus propios hogares (D. K. Anderson et al., 2014), el resto vive con sus familias al menos hasta la mediana edad. Después pueden acabar en centros de cuidados especiales donde tienen los apoyos necesarios para la vida diaria. Mantener una relación íntima a largo plazo sigue siendo muy poco frecuente, sobretodo en aquellos individuos menos capaces (Howlin et al., 2013).

Por último, con respecto a los datos de mortalidad prematura, éstos aumentan significativamente en aquellos individuos que tienen menores capacidades intelectuales, así como en las mujeres (debido sobretodo a anomalías congénitas y trastornos

neurológicos), pero también afecta a aquellas personas que son más capaces con diagnósticos comórbidos (Hirvikoski et al., 2016).

Si miramos los datos en España, no se conoce con exactitud el número de personas con TEA. Sin embargo, atendiendo a los datos obtenidos por la Comisión Europea dentro del proyecto *Autism Spectrum Disorders in the European Union* (ASDEU) (Comission, 2018), en el cual se indica una prevalencia de 12,2 por cada 1000 (1 de cada 89) en niños y niñas comprendidos en edades de entre 7 y 9 años, se estima que en España pueden haber más de 450.000 casos, y por lo tanto, se eleva a casi un millón y medio de personas vinculadas al TEA teniendo en cuenta el impacto que produce en las familias de las personas que lo padecen.

Desde el punto de vista de la sociedad, existe un gran desconocimiento de esta patología. Lo que la ciudadanía en general suele concebir del TEA es aquello que los medios de comunicación han mostrado y que en ocasiones no da una imagen real de lo que significa padecerlo. Por lo tanto, los medios de comunicación actúan como formadores de opinión y juegan un papel fundamental para ayudar a todos a entender mejor la manera de ver el mundo que tienen las personas que padecen TEA.

Es importante comprender las necesidades especiales que requieren las personas que sufren este trastorno. Los niños con TEA tienen una menor probabilidad de recibir una educación adecuada a sus necesidades. Al igual que los adultos que sufren este trastorno tienen una probabilidad de encontrar trabajo mucho menor que las personas con un desarrollo neurotípico. Por ello, las personas que sufren de TEA tienen una mayor vulnerabilidad a la pobreza una vez llegada la etapa adulta. Existen movimientos para la defensa de las personas con TEA que destacan la necesidad de conseguir un mayor respeto por la neurodiversidad, los puntos fuertes de las personas que lo sufren, como por ejemplo la atención en los detalles más insignificantes, o las diferencias individuales, que exigen que el TEA sea considerado como una condición y no un trastorno. Por otro lado, los padres o cuidadores de las personas con TEA que tienen una discapacidad intelectual o visto de otra manera, son menos capaces, expresan la preocupación de que este hecho junto con centrar la atención de los medios de comunicación en aquellos individuos más inteligentes, pueda restar importancia a las deficiencias y requerimientos especiales que necesitan aquellos niños y adultos con TEA que sufren de un modo más severo este trastorno.

1.1.1 Influencia del Trastorno del Procesamiento Sensorial

La integración sensorial puede definirse como la organización de la información de los sentidos para su uso (Ayres, 1972). Se trata de un proceso neurológico que permite al individuo dar sentido al entorno que le rodea. Sin embargo, se estima que el 95 % de las personas con TEA, presentan también un Trastorno del Procesamiento Sensorial (TPS) (Pfeiffer et al., 2013; Leekam et al., 2007; Baker et al., 2008). Este trastorno afecta a la forma en que el sistema nervioso procesa la información sensorial, es decir, los estímulos (esto incluye las cosas que se ven, se oyen, se huelen, se saborean o se tocan). El TPS puede afectar a uno, varios o todos los sentidos. En el caso de personas con TEA, estos problemas están relacionados con las dificultades en la interacción social, en el aprendizaje y en el propio comportamiento de la persona. En el Manual Diagnóstico y Estadístico de los Trastornos Mentales - 5ª edición (DSM-V), se reconoce como criterios diagnósticos del TEA las alteraciones hipo o hiper reactivas a los estímulos sensoriales o un interés inusual por los aspectos sensoriales del entorno (*Diagnostic and statistical manual of mental disorders (5th ed.) 2013*). Las personas con TEA muestran una gran heterogeneidad en sus comportamientos sensoriales atípicos. Algunos individuos no responden cuando perciben determinados sonidos y otros son extremadamente sensibles a ciertos sonidos considerados como sonidos suaves por la mayoría. Lo mismo ocurre con los estímulos visuales, táctiles, olfativos y gustativos.

Las alteraciones sensoriales provocadas por el TPS afectan significativamente a las actividades de la vida diaria y contribuyen a un comportamiento desafiante y al aislamiento social (Ortiz Huerta, 2014). Las conductas desafiantes son, en su gran mayoría, el resultado de un estímulo negativo para la persona, que le provoca un malestar, el cual prolongado en el tiempo pueda acabar derivando en una crisis de conducta. Debido a una hipersensibilidad en algunos de los sentidos en las personas con TEA, cualquier cambio en el entorno puede motivar este tipo de conductas desafiantes, histéricas e incluso agresivas en algunas situaciones, que deben de ser intervenidas (Hill et al., 2014). Cuando se habla de intervención, se define como "*Cualquier método de respuesta a la conducta que implica algún grado de fuerza física dirigida al limitar o restringir el movimiento o la movilidad*" (Harris et al., 1997), para evitar que el individuo se hiera a sí mismo o a otros.

Sin embargo, es inevitable que surjan nuevas situaciones en la vida diaria de una persona y por tanto estímulos externos que no se pueden controlar. Aún así, para las personas con TEA es importante tratar de dirigir la mayoría de las circunstancias a las

que se enfrentan de modo que conozcan con antelación lo que va a ocurrir para no verse afectados por los posibles cambios del entorno que les rodea.

1.2 HIPÓTESIS Y APORTACIONES DEL TRABAJO

El presente trabajo contiene algunas aportaciones originales en el campo de la bioelectrónica y la inteligencia artificial. En particular, el uso de sistemas electrónicos de monitorización y algoritmos de aprendizaje automatizado para la mejora de la calidad de vida en personas que sufren TEA. Algunas de estas aportaciones en orden de aparición son:

- Se ha analizado el comportamiento de personas con TEA frente a estímulos del entorno, dado que aquellos que sufren de un TPS asociado se ven afectados por los cambios que ocurren a su alrededor. Se ha estimado cuáles son aquellos parámetros que más les afectan a su comportamiento.
- Se ha desarrollado un dispositivo de monitorización de variables fisiológicas especialmente diseñado para personas con una alta sensibilidad, lo cual les hace ser reticentes al uso de nuevo objetos y cuerpos extraños.
- Se ha desarrollado un sistema de monitorización del entorno, inteligente y portátil. Uno de los dispositivos del sistema integra diferentes algoritmos que proporcionan información visual sobre el entorno donde se encuentra el usuario.
- Se ha implementado una arquitectura de trabajo donde la información adquirida por todos los dispositivos de la plataforma se almacenan en una base de datos remota. Esta centralización de los datos permite acceder a la información en tiempo real y desde cualquier parte.
- Se ha validado el uso de los dispositivos de monitorización en una experimentación con usuarios sin ninguna patología. También se ha construido un clasificador de actividades a partir de la información obtenida durante el desarrollo de la experimentación.
- Se ha estudiado el uso de la ingeniería de atributos como herramienta para construir modelos predictivos de comportamiento frente a estímulos del entorno, a partir de la información proporcionada por los dispositivos de monitorización desarrollados en este trabajo.

- Se ha evaluado el uso de la plataforma desarrollada en usuarios con **TEA** dentro de un entorno clínico. También se han utilizado técnicas de machine learning para extraer información sobre los usuarios y las tareas llevadas a cabo durante las sesiones clínicas.
- Se ha desarrollado un algoritmo para la reconstrucción de la señal de frecuencia cardíaca cuando la señal se corrompe debido a los artefactos de movimiento utilizando técnicas de aprendizaje automatizado.

1.3 MOTIVACIÓN DEL TRABAJO

Las anomalías en la respuesta ante estímulos del entorno en personas con **TEA** han sido algo observado desde los primeros diagnósticos del trastorno. Sin embargo, en el pasado estos síntomas se han considerado como algo externo y no como una característica principal del **TEA**. En los últimos años, se ha reconocido cada vez más la importancia de estos síntomas sensoriales en el **TEA** y muchas investigaciones han demostrado la frecuencia y el papel que desempeñan en las características y las deficiencias funcionales del **TEA** (Baker et al., 2008; Tomchek y Dunn, 2007; Klintwall et al., 2011).

Los problemas en el procesamiento sensorial afectan a la vida diaria de las personas que los padecen. Éstos se ven además acrecentados en las personas con **TEA**, sobretudo en aquellas que lo sufren en un grado más severo. La dificultad para ir al colegio, ir a trabajar o simplemente relacionarse con otras personas se dificulta todavía más. Por ejemplo, podemos imaginar una situación en la que un niño con **TEA** que padece una hipersensibilidad a estímulos entra en un centro comercial. La cantidad de estímulos a su alrededor (luces, ruidos, cantidad de personas, etc) le puede acabar provocando una crisis de conducta en la que halla que intervenir, y abandonar el lugar para tratar de relajarle. Su sistema nervioso no es capaz de absorber todos esos estímulos presentes en el entorno y ordenarlos de una manera en la que la persona sea capaz de centrarse sólo en aquellos que desea, y se ve desbordado. Esta situación es un caso bastante extremo dado que la cantidad de estímulos presentes en un centro comercial puede llegar a ser excesiva incluso para personas que no padecen un **TPS**. Sin embargo, es una situación que a menudo se repite en la vida de las personas con **TEA** cuando realizan actividades de la vida cotidiana.

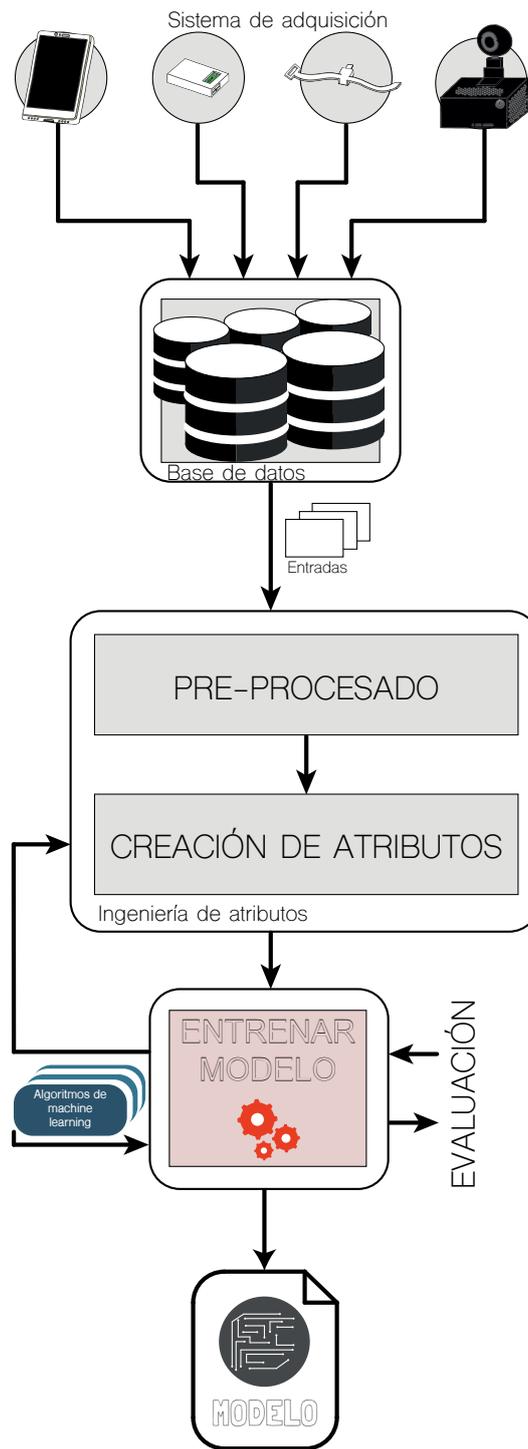


Figura 1.1: Esquema conceptual de la arquitectura de trabajo en la plataforma desarrollada.

Lo que se plantea en esta tesis es el desarrollo de una plataforma que analice los estímulos del entorno en la vida de personas con TEA que sufren estos problemas sensoriales, y mediante técnicas de Aprendizaje Automatizado (AA) establecer una relación entre los cambios en el entorno y los cambios en el comportamiento de la persona. En la Figura 1.1 se muestra un esquema de concepto del sistema. Se propone el desarrollo de un sistema de adquisición de datos modular formado por múltiples dispositivos que se encargan de medir tanto los diferentes estímulos del entorno como parámetros fisiológicos del usuario que permitan evaluar los cambios en su estado vital, para después utilizar esa información adquirida con el sistema de adquisición y generar un modelo predictivo personalizado del comportamiento del usuario frente a los estímulos. Para ello, se establece una arquitectura de trabajo en la que se llevan a cabo diferentes tareas (adquisición, gestión de la información, generación de atributos, evaluación de algoritmos de AA, etc), hasta obtener los modelos predictivos.

La construcción de este sistema implica un estudio previo que nos ayude a entender de qué manera afectan los diferentes estímulos presentes en el día a día de una persona con TEA antes de seleccionar aquellos que se integrarán en el sistema de monitorización. Para ello, tras la realización de un curso de formación práctica en la patología del TEA, se ha elaborado un análisis en colaboración con especialistas en diagnóstico y tratamiento del TEA para evaluar esos estímulos. Los resultados de este estudio se resumen en la Tabla 1.1.

La Tabla 1.1 enumera casi todos los posibles estímulos que pueden afectar al estado de una persona con TEA. Todas las variables mostradas fueron evaluadas según diferentes características para decidir si se incorporan al sistema de adquisición. Las dos primeras columnas especifican si el parámetro se mide del entorno o del usuario. Las dos siguientes columnas indican si el parámetro es un estímulo que tendrá influencia en un cambio en el estado físico del usuario (es decir, un motivo de cambio) o un parámetro cuya modificación implica que hay un cambio en el estado del usuario (es decir, una consecuencia). Las columnas de "Facilidad de medida" y "Facilidad de integración" precisan si los sistemas para la medida del parámetro son sencillos y si el sistema para la medida es fácil de integrar en el sistema de adquisición, respectivamente. La columna de "Asignación clínica" señala uno de los aspectos más importantes del estudio. Se trata de una asignación numérica, siendo 10 la nota más alta, sobre la probabilidad de que el parámetro tenga impacto en un cambio de estado en el usuario. Los valores que se muestran en esta columna han sido asignados en colaboración con profesionales del Centro Infanta Leonor para personas con TEA en Alicante, España. Por último,

se marca si el parámetro ha sido seleccionado o no para integrarse en el sistema de adquisición en base a las columnas anteriormente descritas.

Los dos primeros parámetros que aparecen en la tabla (variables biológicas y educacionales), pueden afectar al estado físico y cognitivo del usuario y están formados por múltiples factores. Estas colecciones de propiedades no son viables de medir dentro del sistema de adquisición y se consideran como modificadores dentro del sistema. En la Tabla 1.2 se listan los principales factores que se corresponden con estas colecciones de parámetros. Por un lado, las variables biológicas que están relacionadas con una correcta alimentación que ayude a un buen comportamiento de la persona, una medicación ajustada durante el día o la semana, cómo puede afectar los cambios hormonales en la

Tabla 1.1: Parámetros estudiados para el sistema ambulatorio de monitorización.

	Personal	Ambiente	Razón	Consecuencia	Facilidad de medida	Facilidad del integración	Asignación clínica	Variable seleccionada
VARIABLES EDUCACIONALES	✓	✓	✓		No	No	9	No
VARIABLES BIOLÓGICAS	✓		✓		No	No	8	No
Cantidad de personas en el entorno		✓	✓		No	Si	10	Si
Relación con las personas en el entorno		✓	✓		No	No	8	No
Temperatura corporal	✓			✓	Si	Si	-	Si
Temperatura ambiente		✓	✓		Si	Si	8	Si
Presión atmosférica		✓	✓		Si	Si	0	Si
Humedad relativa		✓	✓		Si	Si	0	Si
Luminosidad		✓	✓		Si	Si	6	Si
Frecuencia cardíaca	✓			✓	Si	Si	-	Si
Ruido ambiente: Sonoridad		✓	✓		Si	Si	10	Si
Ruido ambiente: Frecuencia		✓	✓		Si	Si	10	Si
Actividad electrodermal	✓			✓	Si	No	-	No
Tacto: texturas	✓		✓		No	No	5	No
Contacto humano	✓		✓		No	No	10	No
Olores		✓	✓		No	Si	8	No
Sabores	✓		✓		No	No	6	No
Actividad física	✓		✓	✓	Si	Si	6	Si
Actividad electromiográfica	✓			✓	Si	No	-	No
Estimulación visual: Colores		✓	✓		No	Si	1	No
Estimulación visual: Formas		✓	✓		No	Si	1	No
Estimulación visual: Ritmo		✓	✓		No	Si	3	Si
Equilibrio corporal	✓		✓		No	No	5	No
Propiocepción	✓		✓		No	No	8	No

Tabla 1.2: Principales factores de las variables educacionales y biológicas.

Variables biológicas	- Medicación
	- Nutrición
	- Fluctuaciones hormonales
	- Descanso
Variables educacionales	- Agenda
	- Ocurrencias espontáneas
	- Hacer una elección
	- Actividades

persona (por ejemplo, durante el período menstrual en sujetos de género femenino), o qué tal descansa esa persona. Por otro lado, las variables educacionales que guardan relación con como se comporta la persona ante cambios imprevistos, la necesidad de seguir una agenda marcada, el deseo de realizar ciertas actividades y no otras, etc.

En el estudio, se han evaluado un total de 24 variables, de las cuales 12 han sido clasificadas como parámetros personales, es decir, que se miden sobre el usuario, y 12 como parámetros ambientales, es decir, medidos del entorno. Las variables educacionales pueden considerarse tanto personales como ambientales dado que algunos factores dependen de la actuación del usuario directamente. Entre todas las variables, 20 han sido consideradas como posibles motivos de cambio en el usuario, es decir, estímulos que pueden provocar un cambio en la persona. Las 4 variables restantes, más la actividad física que se considera tanto motivo como consecuencia, han sido clasificadas como variables que miden los posibles cambios en el usuario. Finalmente, entre todas las variables se han seleccionado 11 para ser integradas en el sistema de adquisición. Dado que el sistema de adquisición es modular y está compuesto por varios dispositivos, tres de estas variables estarán integradas en el dispositivo ambulatorio de monitorización de bioseñales y las ocho restantes en los sistemas de monitorización del entorno.

1.4 ESTRUCTURA DE LA TESIS

Esta tesis se enmarca dentro de los campos de la bioelectrónica y la inteligencia artificial. Se busca alcanzar los siguientes objetivos: el desarrollo de una plataforma de dispositivos electrónicos para monitorización de personas con TEA capaz de obtener información del usuario y del entorno; y el tratamiento y empleo de las señales obtenidas para la generación de modelos predictivos personalizados al usuario mediante el uso de algoritmos de aprendizaje automatizado.

Los principales resultados de esta tesis se han publicado en dos artículos en sendas revistas indexadas en el *Scimago Journal & Country Rank* (SJR).

El documento se estructura en ocho capítulos, en los cuales se desarrollan todos los trabajos realizados y cuyo resultado son los dos artículos principales. Se incluye un capítulo de introducción, otro comentando el estado del arte y un capítulo final de conclusiones y trabajos futuros. Así, el documento queda estructurado de la siguiente manera:

- **CAPÍTULO 1:** Introducción a la patología del TEA y el impacto que supone a la sociedad actual, los aspectos a tener en cuenta al trabajar con personas con TEA, un resumen de las aportaciones del trabajo, el planteamiento sobre el que se desarrolla el trabajo de esta tesis y un listado con las principales publicaciones.
- **CAPÍTULO 2:** Estudio del estado del arte de los principales campos en los que se enfoca la tesis doctoral. Primero se evalúan los procedimientos y actuaciones necesarias con personas con TEA desde el punto de vista clínico. Seguidamente se hace una revisión de los sistemas ambulatorios existentes para la monitorización de bioseñales, prestando atención en aquellos desarrollados para usuarios con características especiales y sistemas de monitorización del entorno. Finalmente, se realiza un repaso de los principales métodos de aprendizaje automatizado utilizados en el campo de la medicina.
- **CAPÍTULO 3:** Desarrollo del dispositivo electrónico de monitorización personal, descripción de los diferentes sensores integrados en el dispositivo y aspectos del uso y fabricación del dispositivo.
- **CAPÍTULO 4:** Desarrollo de los dispositivos electrónicos de monitorización del entorno. En primer lugar, descripción del dispositivo de adquisición de condiciones del entorno y los sensores que se integran en él. Seguidamente, descripción del dispositivo inteligente de adquisición de estímulos visuales y los

algoritmos integrados en él. En ambos casos se muestran también aspectos del uso y fabricación o montaje de los dispositivos.

- **CAPÍTULO 5:** Descripción de la aplicación móvil que gestiona los dispositivos electrónicos de adquisición y de la arquitectura de almacenamiento de la información.
- **CAPÍTULO 6:** Obtención y creación de atributos para entrenamiento de modelos predictivos personalizados al usuario. Descripción del proceso de entrenamiento de modelos predictivos incluyendo una relación con los principales algoritmos de aprendizaje automatizado.
- **CAPÍTULO 7:** Descripción del protocolo de experimentación utilizado con usuarios con TEA en un estudio clínico y los resultados obtenidos.
- **CAPÍTULO 8:** Desarrollo de un algoritmo para la reconstrucción de la frecuencia cardíaca en tareas donde aparecen artefactos de movimiento utilizando técnicas de aprendizaje automatizado.
- **CAPÍTULO 9:** Finalmente, en el último capítulo se exponen las conclusiones obtenidas durante el desarrollo de la tesis doctoral y se presentan las líneas de trabajos futuros.
- **CAPÍTULO 10:** Se incluye un capítulo con las conclusiones en inglés para cumplir con la normativa del Programa de Doctorado como Tesis Doctoral Internacional.

1.5 PUBLICACIONES

El trabajo realizado durante la tesis doctoral ha dado como resultado las siguientes publicaciones:

- Vicente-Samper, J. M.; Ávila-Navarro, E. y Sabater-Navarro, J. M. (2020), «Data Acquisition Devices Towards a System for Monitoring Sensory Processing Disorders», *IEEE Access* **8**, págs. 183596-183605, DOI: [10.1109/ACCESS.2020.3029692](https://doi.org/10.1109/ACCESS.2020.3029692)
- Vicente-Samper, J. M.; Avila-Navarro, E.; Esteve, V. y Sabater-Navarro, J. M. (2021), «Intelligent Monitoring Platform to Evaluate the Overall State of People with Neurological Disorders», *Applied Sciences* **11**(6), DOI: [10.3390/app11062789](https://doi.org/10.3390/app11062789)

ESTADO DEL ARTE

Este capítulo se divide en cuatro partes distintas. En la primera de ellas se realiza una revisión sobre los desafíos que supone el TEA desde un punto de vista clínico. En la segunda parte, se estudian algunos de los sistemas ambulatorios de monitorización comerciales más destacados, con especial interés en aquellos que han sido desarrollados pensando en personas que sufren alguna patología. En tercer lugar, se analizan diferentes sistemas de análisis del entorno, buscando que integren alguna función añadida sobre los sistemas tradicionales de medida del entorno. Finalmente, se realiza una revisión del uso de la inteligencia artificial aplicada a la medicina.

2.1 APORTACIONES CLÍNICAS AL TRASTORNO DEL ESPECTRO DE AUTISMO

La última edición del *DSM-V* (*Diagnostic and statistical manual of mental disorders* (5th ed.) 2013) agrupa los criterios que definen el TEA en dos grandes grupos como ya se ha mostrado anteriormente (problemas de interacción social y comunicación, y problemas de comportamiento o conductas restringidas y repetitivas), en lugar de los tres grupos que diferenciaba en la 4ª edición (déficits sociales, déficits del lenguaje y conductas repetitivas). Además, el *DSM-V* elimina los subtipos de diagnóstico dentro del TEA que estaban presentes en la anterior edición (Trastorno Generalizado del Desarrollo, Síndrome de Asperger, Trastorno Desintegrativo Infantil (TDI), Trastorno Generalizado del Desarrollo no especificado y Autismo). Por último, también elimina los criterios de edad de inicio y añade parámetros especificadores (como trastornos neurobiológicos, factores de riesgo o factores genéticos) y modificadores como el lenguaje, los niveles cognitivos y de aprendizaje y el Trastorno por Déficit de Atención e Hiperactividad (TDAH). El *DSM-V* proporciona unas directrices para fundamentar el diagnóstico aunque tiene ciertas limitaciones, sobretodo en el caso de niños menores de 5 años, en los cuales la especificidad parece además baja (Christiansz et al., 2016). Los niños menores de 5 años pueden tener síntomas insuficientes respecto a los comportamientos restrictivos y repetitivos. Por ejemplo, los niños más pequeños suelen

tener fascinación por el uso repetitivo de objetos, movimientos con las manos y los dedos o intereses sensoriales inusuales, sin embargo, los rituales y la reticencias a cambios son más comunes a aumentar con la edad. En conclusión, los criterios marcados por el [DSM-V](#) proporcionan una estructura básica para evaluar el [TEA](#) en todas las edades, aunque son más problemáticas en los niños más pequeños.

Respecto al tratamiento del [TEA](#), no existe un tratamiento único. Los tratamientos varían en función de las características de cada persona, y pueden incluir sesiones educativas intensivas para el desarrollo de habilidades y enseñanzas, sesiones para el análisis y corrección de la conducta, sesiones interactivas centradas en la propia persona que permitan también influir en la formación de los padres o cuidadores, terapias de mejora del habla y del lenguaje, terapias ocupacionales, sesiones de formación en habilidades sociales, etc. Es también común el uso de tratamientos complementarios a las sesiones clínicas entre las personas con [TEA](#), por ejemplo, los suplementos nutricionales y las dietas especiales. Además, algunos niños y adultos con [TEA](#) presentan otros tipos de dificultades psicológicas en algún momento de sus vidas, por ejemplo, problemas de ansiedad, [TDAH](#) o comportamientos depresivos. Estas dificultades pueden ser tratadas con medicación.

Tras los estudios revisados por ([Weitlauf et al., 2014](#)) acerca de las intervenciones en el comportamiento como tratamiento para el [TEA](#), el Análisis Conductual Aplicado ([ACA](#)) se asoció con una mejora del funcionamiento cognitivo y de las habilidades lingüísticas en niños pequeños y adolescentes ([Tiura et al., 2017](#)). Por ejemplo, la Intervención Conductual Intensiva Temprana ([ICIT](#)) es un tratamiento establecido para niños pequeños con [TEA](#) que se basa en los principios del [ACA](#). Si se lleva a cabo durante un período de varios años con una media de 20 a 40 horas semanales, puede proporcionarle un beneficio sustancial a los síntomas principales del [TEA](#), especialmente en aquellos que afectan a las habilidades de comunicación ([Reichow et al., 2012](#)). En cuanto a los adultos con [TEA](#), existen estudios observacionales que muestran que los grupos de habilidades sociales pueden ser eficaces para mejorar la interacción social ([Hillier et al., 2007](#)). Por ejemplo, la Terapia Cognitivo-Conductual ([TCC](#)) puede ayudar a los adultos con [TEA](#) en el tratamiento de la ansiedad y los trastornos obsesivo compulsivos ([Lang et al., 2010](#)).

El tratamiento psicofarmacológico de las personas con [TEA](#) es un reto debido a la enorme heterogeneidad de las personas que lo padecen. Las personas con [TEA](#) suelen ser más vulnerables a los efectos secundarios de los medicamentos que los individuos que comparten edad con ellos y tienen un desarrollo neurotípico ([Accordino et al., 2016](#)).

Además, la mayoría de la información existente sobre medicación psicotrópica para personas con TEA es referida a edades pediátricas, sin embargo, el trastorno acompaña a las personas a lo largo de su vida. Como se establece anteriormente, no existe en la actualidad un medicamento aprobado para el tratamiento de los síntomas principales del TEA (déficits en la comunicación social o problemas de conducta repetitiva y restringida). El tratamiento farmacológico está principalmente orientado a mitigar los problemas de hiperactividad, falta de atención, impulsividad, irritabilidad, agresividad, conductas autolesivas, conductas estereotipias y el insomnio (Stepanova et al., 2017).

2.2 SISTEMAS AMBULATORIOS DE MONITORIZACIÓN DE BIOSEÑALES

El gran avance de la electrónica en las últimas décadas y la aparición de los dispositivos electrónicos inteligentes han favorecido el desarrollo de nuevos sistemas de monitorización ambulatoria. A partir de los caros y voluminosos sistemas que anteriormente sólo se disponía de ellos en hospitales o centros de investigación, ahora existe una gran variedad de sistemas como son las pulseras de actividad o los relojes inteligentes, y cada vez integran más funcionalidades.

En el mercado existen multitud de dispositivos comerciales. La mayoría de ellos permiten tener un mejor control sobre la actividad diaria o proporcionan información acerca de la actividad física o la energía consumida durante ésta. Sin embargo, algunos de ellos incluso poseen certificación médica para determinados sensores. Por ejemplo, el *Apple Watch* (Apple, 2021), el reloj inteligente de la compañía *Apple*, desde la Series 4 incorpora un sensor eléctrico, además del óptico para la medida de la frecuencia cardíaca, que le permite medir la señal de Electrocardiograma (ECG) del usuario. Este dispositivo genera una señal de ECG similar a la de un ECG de una sola derivación, que mediante un algoritmo le permite detectar arritmias indicativas de fibrilación articular en el usuario. El sensor fue sometido a estudio (Apple, 2020) y la función ha obtenido la clasificación "De Novo" o "510K" de la Food and Drug Administration (FDA) estadounidense. Esta función también se encuentra disponible en varios países europeos, entre ellos España. Otros ejemplos similares son el "*Samsung Galaxy Watch 3*" (Samsung, 2021) o el "*Fitbit Sense*" (Fitbit, 2021), que también poseen la certificación por parte de la FDA en el sensor de ECG para la detección de arritmias indicativas de fibrilación articular en el usuario.

Otros sistemas de monitorización ambulatoria son las bandas pectorales de actividad física. Estos sistemas en general proporcionan una información más completa que los relojes inteligentes o las pulseras de actividad. Estos dispositivos, que se sitúan en el torso del usuario poseen mayor estabilidad en la medida que los dispositivos que se sitúan en el brazo dado que se ven menos afectados por el movimiento del usuario. Por otro lado, son más incómodos y no están pensados para realizar una monitorización continua con ellos sino únicamente para llevarlos durante el desarrollo de la actividad física. Un claro ejemplo de estos sistemas es el "*Zephyr BioHarness*" de *Medtronic* (*Medtronic, 2021*). Se trata de un sistema de monitorización de banda pectoral muy utilizado por deportistas de élite, militares y sobretodo dentro del mundo académico y la investigación. Este sistema proporciona la frecuencia cardíaca y su variabilidad, la frecuencia respiratoria, así como información sobre la posición y el movimiento del usuario, entre otras cosas.

2.2.1 *Dispositivos diseñados para usuarios con características especiales*

Por otro lado, si se enfoca el uso de estos sistemas de monitorización ambulatoria para ayudar a personas con alguna afección neurológica como son por ejemplo el TEA, el Alzheimer o la epilepsia, pueden resultar muy útiles. Las personas que padecen algún desorden neurológico requieren de un control casi continuo por su parte o la del cuidador y el uso de sistemas que les puedan ayudar a controlar su estado mejora su calidad de vida. En este contexto, los sistemas de monitorización ambulatoria se convierten en Tecnologías Asistenciales (TA), es decir, dispositivos o sistemas que se utilizan para ayudar a las personas con dificultades o trastornos a realizar las actividades de la vida diaria.

Las TA pueden contribuir a mejorar la independencia funcional, y por tanto, a facilitar las tareas cotidianas de una persona como desplazarse, comunicarse con otros, aprender, trabajar o participar en actividades sociales y recreativas (*Disease Control y Prevention, 2021*). Algunos de estos dispositivos de asistencia tratan de ayudar a gestionar los problemas asociados a los trastornos neurológicos y facilitar la vida diaria tanto a las personas que lo padecen como a los familiares o miembros de apoyo que les ayudan a lo largo de sus vidas. Un ejemplo de esto es el dispositivo *Embrace* de *Empatica* (*Empatica, 2021*). Se trata de un dispositivo wearable de muñeca enfocado a usuarios que padecen epilepsia. El dispositivo monitoriza al usuario de una manera continua para detectar posibles ataques convulsivos y alertar a los cuidadores o la

persona de emergencia del usuario. Otro ejemplo de sistema de monitorización es el *PdMonitor*© de *PD Neurotechnology* (Neurotechnology, 2021). Consiste en un conjunto de dispositivos de monitorización wearables, en este caso enfocado a personas con trastorno de Parkinson. El dispositivo rastrea, registra y procesa una serie de síntomas a menudo presentes en esta enfermedad. Un tercer ejemplo es el sistema *Monarch eTNS*© de *NeuroSigma* (NeuroSigma, 2021). Es el primer dispositivo aprobado por la FDA para el tratamiento del TDAH. El dispositivo envía un pulso eléctrico de bajo nivel a través de un cable a un pequeño parche adherido a la frente del paciente. Los pulsos terapéuticos estimulan las ramas del nervio trigémino, que activa la vía neuronal hacia otras partes del cerebro que se creen están implicadas en el TDAH.

Se pueden encontrar también multitud de trabajos de investigación para el desarrollo de TA con sistemas de monitorización ambulatoria. Por ejemplo, el trabajo de (Cesareo et al., 2020) presenta un sistema para monitorizar la frecuencia respiratoria en personas con distrofia muscular. El sistema consiste en un conjunto de unidades de medida inercial integradas en dispositivos wearables para controlar el patrón de respiración del usuario. En (Omar et al., 2019) se presenta una herramienta inteligente para asistir a personas con Alzheimer. El sistema ayuda a monitorizar la salud del usuario, controlar la medicación o localizarlo cuando se desorienta, entre otras cosas. El sistema está compuesto por múltiples dispositivos que monitorizan al usuario, registran su posición y controlan la medicación y los objetos que pueden ser importantes. El propio usuario y los cuidadores tienen acceso a toda la información a través de una aplicación móvil y también reciben alertas.

2.3 SISTEMAS INTELIGENTES PARA LA MEDICIÓN DEL ENTORNO

El seguimiento de las condiciones existentes dentro de un determinado ambiente puede ser necesario para el desarrollo de ciertas tareas. Por ejemplo, existe la obligación de controlar los niveles de ventilación en los locales de pública concurrencia, es decir, la renovación del aire en el interior, y así proporcionar aire limpio del exterior manteniendo unos valores de CO y CO₂ óptimos. También puede ser indispensable el control de las condiciones del entorno en una estancia donde se elabora un proceso industrial el cual puede ser susceptible a cambios, o simplemente monitorizar las condiciones por confort o bienestar dentro de una vivienda.

Los sistemas de monitorización del entorno no son algo novedoso puesto que se vienen utilizando desde hace muchos años en todo tipo de aplicaciones y emplazamientos. Sin embargo, con el auge de la Inteligencia Artificial (IA) en los últimos años han ido apareciendo nuevos dispositivos y sistemas de monitorización que podrían definirse como plataformas o sistemas inteligentes de monitorización. Estos sistemas, además de realizar una monitorización de los parámetros del entorno, incorporan algún tipo de inteligencia en forma de algoritmos de decisión o métodos de AA que mejoran a los sistemas tradicionales y proporcionan una información más completa. Por ejemplo, podemos encontrar el sistema de reconocimiento facial integrado en el sistema de videovigilancia en China (Arana, 2019), donde millones de cámaras repartidas por todo el país monitorizan a la población e identifican los movimientos que realizan. Un sistema similar a menor escala ha sido también implementado recientemente en la ciudad de Belgrado, en Serbia (Pascual, 2021). Otra aplicación donde actualmente se integran este tipo de sistemas es en los vehículos autónomos. Estos vehículos requieren de la mayor cantidad de información posible del entorno para poder tomar decisiones muy precisas. Los sistemas utilizados integran multitud de sensores (cámaras, ultrasonidos, radar, gps, etc) y analizan toda la información recolectada en tiempo real mediante el uso de algoritmos de AA para suministrar información al sistema principal (Khayyam et al., 2020). También se utilizan los sistemas inteligentes de monitorización en el seguimiento de los parámetros ambientales de las ciudades. Estos datos son muy importantes y aportan mucha información. Con ellos se puede medir la calidad del aire o el agua, diseñar sistemas de control de inundaciones, diseñar políticas más eficaces para la sanidad, mejorar la gestión del transporte, tener una mejor respuesta ante una emergencia medioambiental, y otras muchas posibilidades. Un ejemplo es el sistema de monitorización medioambiental que se propone en (Wong et al., 2018). Este trabajo propone medir nueve parámetros diferentes: la temperatura, la humedad relativa, el CO, CO₂, los compuestos orgánicos volátiles, el índice de radiación ultravioleta, el ruido, las partículas PM_{2.5} (diámetro inferior a 2,5 micras) y las partículas PM₁₀ (diámetro inferior a 10 micras). Y a partir de estas medidas poder estimar la calidad del entorno o niveles de sostenibilidad.

2.4 INTELIGENCIA ARTIFICIAL EN LA MEDICINA

En 1955 John McCarthy acuñó el término IA, definiéndolo como "la ciencia y la ingeniería para crear máquinas inteligentes"(McCarthy et al., 1955). Por lo tanto, la IA

es en general la capacidad de una máquina para imitar el comportamiento humano inteligente. Hoy en día la IA está integrada en la vida cotidiana de muchas maneras, como los asistentes personales (Siri, Alexa, Google Assistant, etc), en el transporte masivo automatizado, en la aviación o en videojuegos. La IA también se ha incorporado a la medicina en los últimos años, ya sea para intentar mejorar la atención a los pacientes o lograr una mayor precisión en los diagnósticos, en definitiva mejorar la atención sanitaria general.

En la medicina, los factores más importantes para atender con éxito a los pacientes son el conocimiento y la experiencia, es decir, cuanto más sabes y más pacientes tratas, mejor atención puedes ofrecer. Por lo tanto, los médicos durante su carrera y a medida que atienden a los pacientes aumentan sus conocimientos en sus intereses específicos mediante una formación continua. Esto implica que cuanto más experiencia y datos disponen, serán más capaces de tomar una mejor decisión basada en el conocimiento. Esos datos pueden provenir de documentos de medicina basados en la experiencia como son los libros o los artículos de investigación revisados, mientras que la experiencia se obtiene de los resultados reales y el tratamiento a los pacientes. Sin embargo, la falta de tiempo limita el poder de adquisición de grandes cantidades de datos para la mente humana. Es aquí donde la IA aparece para intentar aprovechar toda esa información existente en bancos de datos transformándola en experiencia que pueda ser útil a la hora de tomar una decisión o establecer un diagnóstico. Mediante la aplicación de algoritmos, los modelos informáticos pueden adquirir más experiencia en un período de tiempo significativamente corto que el que pueden adquirir un ser humano a lo largo de su vida (Mintz y Brodie, 2019).

Por otro lado, el uso de la IA en la medicina tiene dos ramas principales: la virtual y la física (Hamet y Tremblay, 2017). La parte virtual estaría representada por el AA, el cuál implica el uso de algoritmos matemáticos que mejoran el aprendizaje a través de la experiencia. La IA ha impulsado y continúa impulsando grandes descubrimientos en genética y medicina molecular, por ejemplo los algoritmos de interacción proteína-proteína que permitieron descubrir nuevas dianas terapéuticas mediante una combinación de métodos adaptativos de clustering (Theofilatos et al., 2015). Otras aplicaciones virtuales de la IA en la medicina que se pueden encontrar son por ejemplo los historiales clínicos electrónicos, a los cuales se les pueden aplicar algoritmos específicos para identificar sujetos con antecedentes familiares de una enfermedad hereditaria, con un alto riesgo de padecer una enfermedad crónica o ayudar en la detección de enfermedades raras (Brasil et al., 2019). También se aplica

en campos como la radiología debido a los avances en tareas de reconocimiento de imágenes. Con el aumento de expedientes digitales disponibles en combinación con el incremento de potencia computacional, la IA ha pasado a primera línea y son muchos los grupos que trabajan en el desarrollo de algoritmos de procesamiento de imágenes y visión por computador para permitir un diagnóstico más rápido (Esteva et al., 2017; Teare et al., 2017), mejorar la visualización de patologías (Li et al., 2014; Gulshan et al., 2016), alertar en situaciones de emergencias (Prevedello et al., 2017) o ayudar en problemas de falta de personal (Rosenkrantz et al., 2016). Asimismo, la IA es muy útil en el campo de la oncología. Por ejemplo, ofrece resultados incluso mejores que las lecturas humanas en el diagnóstico y estadificación del cáncer de mama (Bejnordi et al., 2017). En la detección del cáncer de pulmón, los algoritmos de AA han demostrado también ser más eficaces que las lecturas humanas. Los resultados en (Yu et al., 2016) sugieren que la IA puede predecir con una gran exactitud el pronóstico de pacientes con cáncer de pulmón, lo que ayuda a mejorar la atención al paciente aplicándole un tratamiento oncológico más adecuado. Se pueden encontrar también multitud de trabajos con IA en campos como la cardiología (Slomka et al., 2017), la gastroenterología (Misawa et al., 2018), la cirugía (Szold et al., 2015) o la oftalmología (W. C. Lin et al., 2020). Aunque la confianza en el diagnóstico por parte de la IA nunca alcanza un 100 %, la combinación entre máquina y médico mejora de forma fiable la atención al paciente.

La segunda de las ramas implica el uso de objetos físicos, dispositivos médicos o robots, los cuáles son cada vez más sofisticados y pueden participar en la prestación de cuidados (Cornet, 2013). Por ejemplo, el uso de un robot de compañía *emocional*, es decir, capaz de estimar el estado anímico de la persona, con personas de edad avanzada que sufren de un deterioro cognitivo o de movilidad limitada. Estos robots son además muy beneficiosos para la mejora de las capacidades sociales y comunicativas en niños con TEA (Kozima et al., 2007). En esta sección se encuentran los dispositivos previamente analizados en 2.2 y 2.2.1. Aquellos dispositivos desarrollados para mejorar la calidad de la vida de las personas con patologías neurocognitivas y que además, integran algún tipo de IA. Por ejemplo, podemos encontrar un sistema para la monitorización en tiempo real de problemas cardiovasculares utilizando imágenes de vídeo y reglas de inferencia difusa en (Casalino et al., 2019). El sistema que se propone está compuesto por un espejo transparente con una cámara que detecta el rostro del usuario. Los fotogramas se procesan mediante fotopletoxiografía para estimar diferentes parámetros fisiológicos del usuario. Estos parámetros estimados se utilizan para predecir el riesgo de enfermedad cardiovascular. Otro sistema que emplea el uso de dispositivos de monitorización y algoritmos de AA está descrito en (Tang et al.,

2019). El sistema está compuesto por dispositivos que monitorizan el movimiento del usuario durante la marcha y estimulan los nervios musculares mediante estimulación eléctrica a través de electrodos. Para ello, en una primera fase se realiza una recogida de datos, y posteriormente se entrena un modelo basado en redes neuronales recurrentes. Finalmente el modelo se encargará de predecir el movimiento del usuario durante la marcha y de controlar la señal de estimulación.

DISPOSITIVO DE MONITORIZACIÓN PERSONAL

En este capítulo se presenta el diseño de un dispositivo de monitorización ambulatoria de señales fisiológicas especialmente diseñado para su uso en personas con TEA. En la primera parte de este capítulo se presentan los requisitos que debe cumplir el dispositivo y se describen los diferentes sensores que integra. Seguidamente, se describe el método de comunicación y control del dispositivo. Por último, se muestra lo relativo a la gestión de la alimentación y el proceso de fabricación y montaje del sistema.

3.1 REQUISITOS DE DISEÑO DEL DISPOSITIVO

Uno de los objetivos marcados en el desarrollo de la tesis es establecer una relación entre los estímulos del entorno y los cambios de comportamiento que se puedan dar en personas con TEA. Es necesario disponer de información acerca del estado del usuario y, por lo tanto, poder cuantificar de algún modo las alteraciones que se producen en él. Para ello, se ha desarrollado un sistema propio de monitorización ambulatoria de señales fisiológicas.

Las personas con TEA muestran una gran heterogeneidad en sus comportamientos sensoriales atípicos. Sin embargo, algo que comparten comúnmente es una alta reticencia a los cuerpos extraños o al uso de nuevos objetos, como ropa, calzado o accesorios. Por esta razón, el uso de sistemas comerciales para la obtención de bioseñales se descartó, ya que la gran mayoría de estos dispositivos tienen un tamaño considerable y pueden ser incómodos incluso para personas que no sufren de este trastorno.

Por otra parte, a la hora de diseñar un dispositivo de este tipo hay que tener en cuenta una serie de consideraciones. Además, dado el uso peculiar que se le va a atribuir a este sistema, también se ha de tener en cuenta las características especiales de los usuarios en los que se va a emplear. Este dispositivo debe pasar lo más desapercibido posible para el usuario. Incluso así, se darán usuarios que no permitan colocárselo o situaciones o días en los que una persona que lo tolera habitualmente, no lo permita.

El sistema debe proporcionar la mayor cantidad de información posible sobre la persona. Sin embargo, incluir demasiados sensores de medida puede acabar incrementando el tamaño del dispositivo en exceso, afectando al requisito anteriormente mencionado. Por consiguiente, se debe alcanzar una solución de compromiso entre el tamaño y peso del dispositivo, y la variedad de información que proporciona sobre el usuario.

Otro aspecto a tener en consideración en el diseño, es la sensibilidad al tacto hacia ciertos materiales que pueden tener las personas con TEA. Por ello, es importante que el sistema no tenga en contacto con la piel partes que puedan resultar ásperas al tacto. De igual modo, evitar partes metálicas o puntiagudas que puedan raspar o pinchar al usuario.

Por último, también será recomendable que el dispositivo se pueda colocar y retirar de una manera sencilla, evitando así aumentar el estrés en la persona cuando se vaya a utilizar.

3.2 SENSORES INTEGRADOS EN EL DISPOSITIVO

El dispositivo de monitorización ambulatoria de bioseñales es el encargado de capturar información de las variables fisiológicas del usuario que han sido seleccionadas en el estudio previamente realizado. De las once variables seleccionadas, tres de ellas son parámetros fisiológicos y por lo tanto, se miden con el dispositivo personal. Estos parámetros son: la temperatura corporal, la frecuencia cardíaca y la actividad motora. Cada uno de ellos tendrá por tanto un sistema para su medida, es decir, un sensor.

3.2.1 *Sensor de temperatura corporal*

La temperatura es una magnitud física que representa la cantidad de energía térmica que hay en una sustancia o una medida de lo caliente que está algo. Para un médico o un cuidador, la temperatura corporal proporciona información valiosa, ya que los seres humanos son criaturas de sangre caliente que tienen la capacidad de mantener la homeostasis, o el equilibrio térmico, independientemente de su entorno (Benzinger, 1969).

La temperatura corporal se regula según un punto de referencia marcado por el hipotálamo (Hammel et al., 1963). Ese valor de referencia varía a lo largo del día en función de los ritmos circadianos de la persona (Ortiz-Tudela et al., 2014) y además, también se ve afectado por posibles traumatismos o enfermedades (Drewry et al., 2013). El calor se genera por metabolismo basal, por la contracción muscular, por ejemplo, al realizar actividad motora (Gordon y Yang, 1997), y también por la ingesta de alimentos. Y se pierde por transferencia de calor (convección, conducción y radiación) y de manera biológica, por sudoración (Campbell, 2008). De igual modo, cuando el cuerpo no puede producir suficiente calor para mantener su homeostasis, los vasos sanguíneos se contraen para conservar el calor. La contracción no es uniforme y afecta en primer lugar a las extremidades del cuerpo, fluyendo menos sangre hacia las extremidades y concentrando el calor en el núcleo, ya que es donde se encuentran la mayoría de órganos vitales (Kellogg, 2006). Por lo tanto, la temperatura del usuario es un parámetro importante que entrega información sobre diferentes aspectos.

La temperatura corporal central T_C puede medirse de varios modos: timpánico, en el conducto auditivo externo, nasofaríngeo, esofágico, rectal, axilar y sublingual (oral). Sin embargo, ninguna de estas opciones es adecuada para disponer un sensor de temperatura en un sistema para uso ambulatorio orientado a personas con TEA. Por ello, se ha optado por medir la temperatura sobre la piel T_S en lugar de la T_C . La piel está formada por tres capas principales distintas (McGrath et al., 2004). La epidermis es la capa más externa y puede considerarse como la barrera del cuerpo frente al mundo exterior. La capa intermedia, la dermis, dispone de sistemas de regulación de la temperatura como son los vasos sanguíneos, las glándulas sudoríparas, las glándulas sebáceas y el músculo erector del bello. Por último, la hipodermis o capa subcutánea, que está formada principalmente por grasa y vasos sanguíneos. Por lo tanto, la T_S es una aproximación a la T_C y proporciona una retroalimentación de la termorregulación del cuerpo (Romanovsky, 2014). Además, existen diferentes estudios en los que se puede llegar a conocer la T_C a partir de la T_S , el flujo de calor y la frecuencia cardíaca del usuario (Welles et al., 2018; Eggenberger et al., 2018).

El sistema de medida integrado en el dispositivo consiste en un sensor con salida digital, por lo que no requiere de ningún procesamiento de señal. Se trata de un sensor específicamente diseñado para la medición de la temperatura del cuerpo humano (MAX30205 (Integrated, 2016)). Proporciona medidas con una precisión de $\pm 0,1^\circ\text{C}$ en el rango que va de los 37°C a los 39°C , cumpliendo así con el estándar ASTM E1112 de

termómetros electrónicos para uso en la determinación intermitente de la temperatura en pacientes (*Standard ASTM E1112-00(2018) 2018*).

La frecuencia de muestreo del sensor se ha establecido a una medición cada 10 segundos. La variabilidad de la temperatura del cuerpo humano es lenta, a pesar de que la temperatura aumenta y disminuye regularmente a lo largo del día, debido principalmente a los ritmos circadianos de la persona (G. Kelly, 2006; G. S. Kelly, 2007). Por lo tanto, se considera que es una tasa lo suficientemente alta como para medir los cambios que se produzcan en la temperatura del usuario. En la Figura 3.1 se muestra una gráfica con la evolución de la temperatura corporal de un usuario medida por el sensor durante una sesión de pruebas. Se puede ver como la curva crece desde el valor de temperatura ambiente hasta la temperatura de la piel del usuario y posteriormente va cambiando en función de las tareas que desarrolla el usuario.

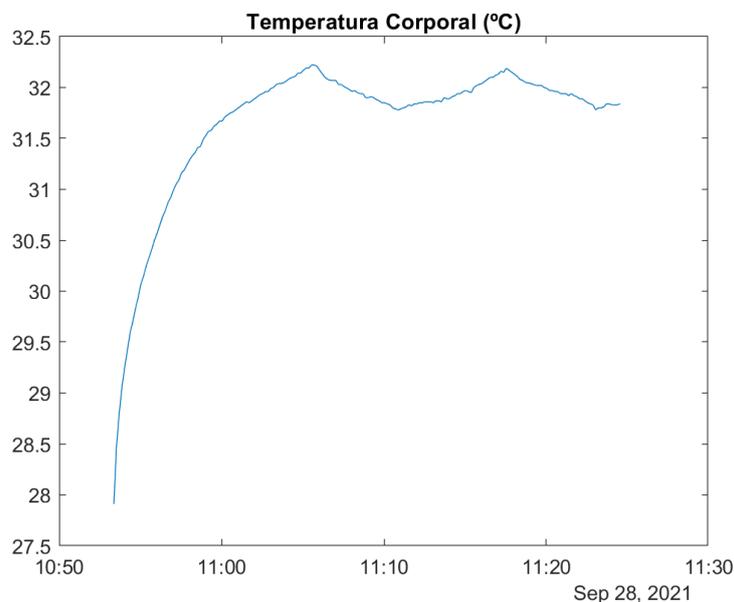


Figura 3.1: Gráfica de la evolución de la temperatura corporal de un usuario medida con el sensor durante una sesión de prueba.

En la Figura 3.2 se muestra una recreación del posicionamiento del sensor de temperatura sobre la muñeca del usuario. En ella se puede observar cómo el calor interno fluye a través de las diferentes capas de la piel hasta llegar al exterior donde se encuentra el sensor de temperatura. Se observa que el contacto entre el sensor y la piel del usuario no es directo, sino que existe una pequeña capa de aire que puede disipar el calor. Sin embargo, en la figura se ha omitido mostrar la carcasa que envuelve al

dispositivo, que aísla por los costados y que evita que se ceda de manera directa calor hacia el exterior. En la Figura 3.11a se muestra una fotografía real del dispositivo donde se observa como éste se encuentra totalmente recubierto y únicamente queda una pequeña apertura por donde los sensores recogen la información.

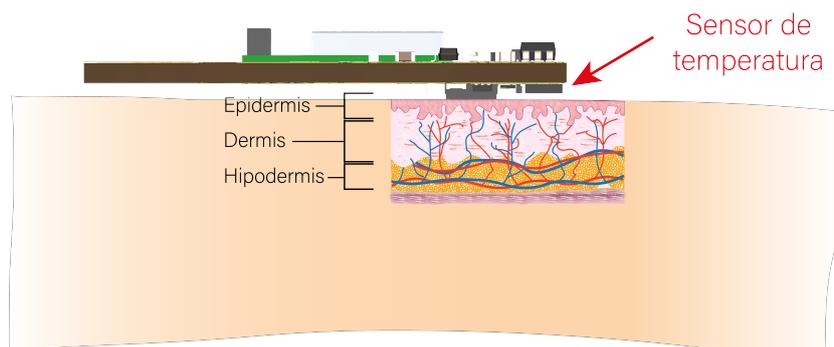


Figura 3.2: Recreación de la medida de la temperatura de la piel T_s en el usuario.

3.2.2 Sensor de frecuencia cardíaca

La FC es una variable clínica muy utilizada y que proporciona información importante sobre el estado físico, ya que además guarda relación con la presión arterial de la persona (Wilkinson et al., 2000). Por ejemplo, un gran aumento continuado en la presión arterial, que a su vez repercute en un aumento en la FC, puede suponer un factor de riesgo de hipertensión primaria o un síntoma de una enfermedad coronaria del corazón (Mulder, 1992). Además, también existen estudios donde se demuestra que es deseable mantener la FC en reposo en valores sustancialmente por debajo del umbral de la taquicardia, definido tradicionalmente entre 90 y 100 Pulsaciones Por Minuto (PPM) (Fox et al., 2007), a pesar de la dificultad de definir la FC óptima para cada individuo.

Por otro lado, el sistema nervioso autónomo es uno de los sistemas principales del cuerpo humano para mantener la homeostasis (Jänig y Häbler, 2000). La actividad del sistema simpático crece cuando una persona se enfrenta a cambios o a situaciones de estrés. Sin embargo, la actividad parasimpática aumenta durante el descanso y la

relajación (Kreibig, 2010). La FC es controlada por modulaciones tanto del sistema simpático como del sistema parasimpático (Uijtdehaage y Thayer, 2000), principalmente marcado por los ritmos circadianos de la persona para mantener la homeostasis (Massin et al., 2000). En consecuencia, además de las condiciones fisiológicas de la persona y sus ritmos circadianos, la interacción con el entorno y el estado psicológico de la persona afectan al equilibrio del sistema nervioso autónomo y eso se verá reflejado a su vez en la frecuencia cardíaca del usuario. Por lo tanto, esta variable aporta información a la hora de pronosticar cambios en el estado del usuario, y más tratándose de personas a las que los estímulos y el cambio les afecta tanto.

Para la medida de la FC se ha integrado un sensor óptico de PPG. La señal de PPG puede ser utilizada para detectar cambios de volumen sanguíneo en el tejido microvascular (Challoner y Ramsay, 1974) y suele utilizarse de manera no invasiva para realizar medidas sobre la superficie de la piel. Esta tecnología se integra en multitud de dispositivos médicos para medir la saturación de oxígeno, la presión arterial o el gasto cardíaco, así como para evaluar la actividad del sistema nervioso autónomo y detectar enfermedades vasculares periféricas (Elgendi et al., 2019).

La medida de la PPG requiere de unos pocos componentes optoelectrónicos. Por un lado, una fuente de luz para iluminar el tejido (en este caso, la piel del usuario). Por otro lado, un fotodetector que mide las pequeñas variaciones en la intensidad de la luz asociadas a cambios en el volumen sanguíneo. Sin embargo, la interacción de la luz con el tejido biológico es muy compleja e incluye procesos ópticos de dispersión, absorción, reflexión, transmisión y fluorescencia (R. R. Anderson y Parrish, 1981). Por lo tanto, no es tan sencillo conseguir aislar el componente deseado en la onda de PPG. Además, la longitud de onda de la fuente de luz también es importante en la interacción con el tejido (Cui et al., 1990). En primer lugar, porque el tejido está compuesto principalmente por agua y ésta absorbe fuertemente la luz en el rango ultravioleta y en las longitudes de onda infrarrojas más largas. Sin embargo, existe un rango en el espectro de absorción del agua que permite que la luz visible roja y las longitudes de onda más cortas del rango infrarrojo atraviesen más fácilmente el tejido, y de ese modo se pueda medir el volumen sanguíneo en esas longitudes de onda. Es por ello, que suelen utilizarse fuentes de luz de color rojo o infrarrojo corto para la medida de PPG (Jones, 1987). Además, la longitud de onda también determina la profundidad a la que la luz penetra en el tejido, ya que la intensidad de la radiación óptica depende de ella (Murray y Marjanovic, 1997).

El sensor de PPG integrado en el dispositivo (MAX86160 (Integrated, 2019)) dispone de dos leds, uno verde y otro infrarrojo, que irradian los pulsos de luz sobre la piel de la muñeca del usuario. La señal reflejada se utiliza para detectar los cambios en el volumen de sangre que se producen en el tejido microvascular, como se explica anteriormente. Sin embargo, la señal de PPG contiene más información de la que se desea extraer, además de ruido. La señal de PPG tiene dos componentes principales, una pulsátil atribuida a cambios cardíacos en el volumen sanguíneo, y una componente basal que varía lentamente y que es atribuida a la respiración, la actividad del sistema nervioso simpático y a la termorregulación. La componente pulsátil suele denominarse componente "AC" y su frecuencia fundamental depende principalmente de la FC. Mientras que la componente basal se denomina "DC" debido a que varía muy lentamente, ya que los factores que lo conforman tienen una menor frecuencia (Allen, 2007). En la Figura 3.3 se muestra una recreación del posicionamiento del sensor de PPG sobre la muñeca del usuario. En ella se puede observar el funcionamiento del sensor, donde el emisor manda los pulsos de luz y tras una serie de fenómenos ópticos la luz se refleja sobre el fotorreceptor. También se muestra en la figura un esquema de las dos componentes que forman la señal de PPG, descritas anteriormente. Además, la señal de PPG también integra artefactos de movimiento que deberán ser eliminados. Por lo tanto, es necesario realizar un procesado para extraer la información deseada.

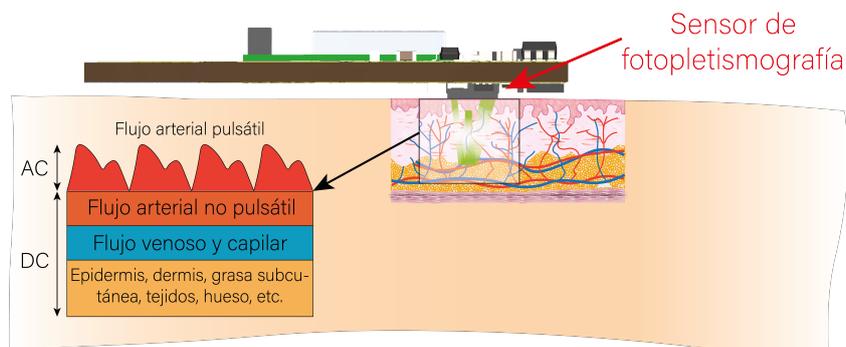


Figura 3.3: Recreación del posicionamiento y medida del sensor de PPG en el usuario. Incluye un esquema con las principales componentes que forman la señal de PPG.

El procesado de la señal de PPG se realiza en ventanas de 6 segundos, con una frecuencia de muestreo del sensor de 20 Hz. Una vez completada una ventana de datos,

se aplican una serie de filtros para eliminar el ruido, separar la componente "AC" de la "DC" y eliminar los artefactos de movimiento. En primer lugar, se aplica un filtro paso banda para eliminar el ruido de alta frecuencia y los artefactos de la componente de baja frecuencia ("DC"), debido a variaciones de temperatura, cambios en la densidad capilar, etc. El rango de frecuencias para el filtro paso banda es entre 0,6 Hz y 3 Hz, donde se encuentra el rango de frecuencia fundamental de la FC. A continuación, se aplica un filtro de mediana con una ventana de 5 muestras para eliminar los posibles picos repentinos que puedan proceder de artefactos de movimiento. Por último, se aplica un filtro paso bajo de Respuesta Infinita a Impulso (FIR), por sus siglas en inglés, para suavizar la señal y eliminar el *baseline*. En la Figura 3.4, se muestra la gráfica de una ventana de datos tomada del sensor de PPG y la evolución de la señal tras cada uno de los filtros aplicados en cada paso del procesado. Se observa como tras el último filtrado se obtiene una señal limpia con un aspecto senoidal. Aplicando la Transformada rápida de Fourier (FFT), por sus siglas en inglés, se obtiene la respuesta en frecuencia y a partir de ésta se extrae la frecuencia fundamental de la señal. Finalmente, se estima la FC del usuario en PPM con la Ecuación 3.1, donde f_0 es la frecuencia fundamental de la señal de PPG tras el procesado.

$$PPM = f_0 * 60 \quad (3.1)$$

3.2.3 Sensor de actividad motora

El papel que juega la actividad física en la salud humana recibe una gran atención en los últimos años tanto dentro de la propia medicina como en el sistema de salud pública, dado que arroja información sobre el estado de las personas. La actividad física está asociada a numerosos procesos funcionales humanos como son la cognición, el sueño y la regulación del peso (Hillman et al., 2008). Además, una baja actividad física está reconocida cada vez más como un factor de riesgo de diabetes (Hamilton et al., 2014), de enfermedades cardiovasculares (Myers et al., 2015), incluso de cánceres (Moore et al., 2016) y trastornos mentales (Vancampfort et al., 2017). Existen varios estudios que han demostrado que los sistemas biológicos implicados en la regulación de la AM están asociados a otros sistemas homeostáticos como el sueño, la conducta alimentaria, la energía y el estado de ánimo (Saper, 2013). Por lo tanto, la AM del usuario es un parámetro muy relevante que proporciona información sobre los movimientos y

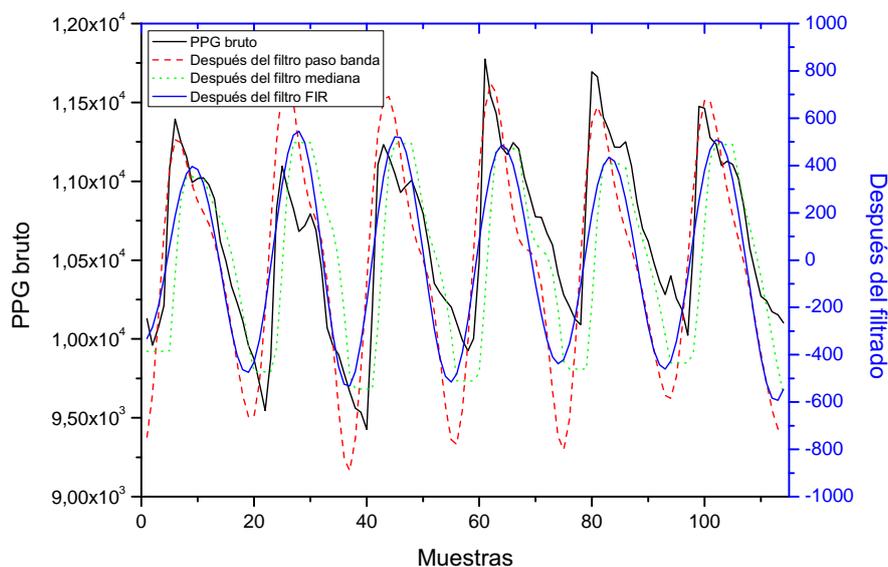


Figura 3.4: Las diferentes etapas del procesado a una ventana de la señal de PPG.

desplazamientos que realiza el usuario. Además, junto con otros parámetros, es posible estimar el estado de ánimo o medir los niveles de estrés del usuario (Can et al., 2019).

Los patrones de la AM se evalúan a través de la actigrafía, en la que un dispositivo proporciona mediciones objetivas y de alta densidad del movimiento físico de la persona. Tradicionalmente, la actigrafía se ha utilizado principalmente para realizar análisis de las características del sueño de un paciente (Zinkhan y Kantelhardt, 2016), sin embargo, el interés por registrar los patrones de actividad motora a lo largo del día, medir la actividad durante el ejercicio físico o controlar la regulación del peso han aumentado considerablemente en los últimos años, sobretodo con la aparición de los dispositivos inteligentes. Además, gracias a este crecimiento del uso de la actigrafía, se dispone de multitud de datos obtenidos en numerosos estudios poblacionales que han entregado información sobre enfermedades, por ejemplo la diabetes (Rockette-Wagner et al., 2017) o enfermedades cardiovasculares (Carson et al., 2013).

La medida de la AM se realiza principalmente en dos posiciones, la AM troncal y la AM de la muñeca. La relación entre los registros medidos en ambas posiciones varía a lo largo del día (Van Hilten et al., 1993). Durante el período nocturno, la AM de la muñeca detecta tanto los movimientos generalizados, por ejemplo los cambios de postura, así como los movimientos que se producen en las extremidades distales, que

no quedarían registrados en la *AM* troncal. Sin embargo, durante el período diurno la relación entre la *AM* de la muñeca y troncal tendrá una variabilidad considerable. No obstante, dada la aplicación en la que se centra este trabajo, el dispositivo registra la *AM* de la muñeca, la cual proporciona información tanto de la actividad generalizada como de los movimientos de las extremidades distales, es decir, del brazo en el que se sitúe el dispositivo de monitorización.

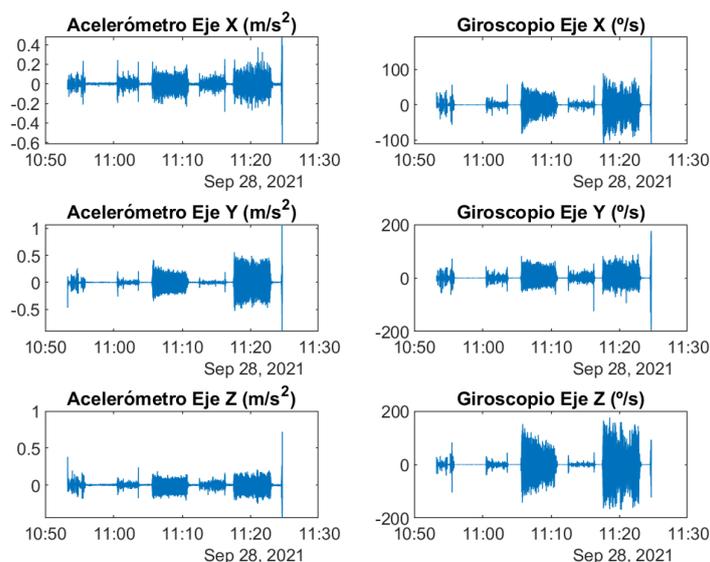


Figura 3.5: Gráficas de la evolución de las señales de aceleración y giroscopio de un usuario medida con el sensor durante una sesión de prueba.

El sensor utilizado para la medición de la *AM* en el dispositivo desarrollado en esta tesis consiste en una Unidad de Medida Inercial (*IMU*), por sus siglas en inglés, (*MPU-9250 (Corporation, 2016)*). Ésta integra un giroscopio de 3 ejes, un acelerómetro de 3 ejes y un magnetómetro de 3 ejes, aunque principalmente se utilizarán los dos primeros. La frecuencia de muestreo del sensor se ha establecido en 4 Hz, a pesar de que la *IMU* tiene una frecuencia máxima de muestreo de una medida cada 100 ms. La elección de esta frecuencia se debe a no saturar el proceso de comunicación entre el dispositivo que gestiona la subida de datos y la base de datos donde se almacena la información. Sin embargo, se ha considerado que 4 medidas por segundo eran suficientes para estimar la *AM* del usuario en cada período. En la Figura 3.5 se pueden ver las gráficas de las señales de los diferentes ejes del acelerómetro y del giroscopio durante una sesión de pruebas. A su vez, en la Figura 3.6 se muestra una recreación

del posicionamiento del sensor de **AM** sobre la muñeca del usuario. Se puede observar como se dispone haciendo coincidir el brazo del usuario con el plano que forman los ejes x e y de la **IMU**, y el eje z estaría en la perpendicular a este plano, con su dirección positiva hacia arriba.

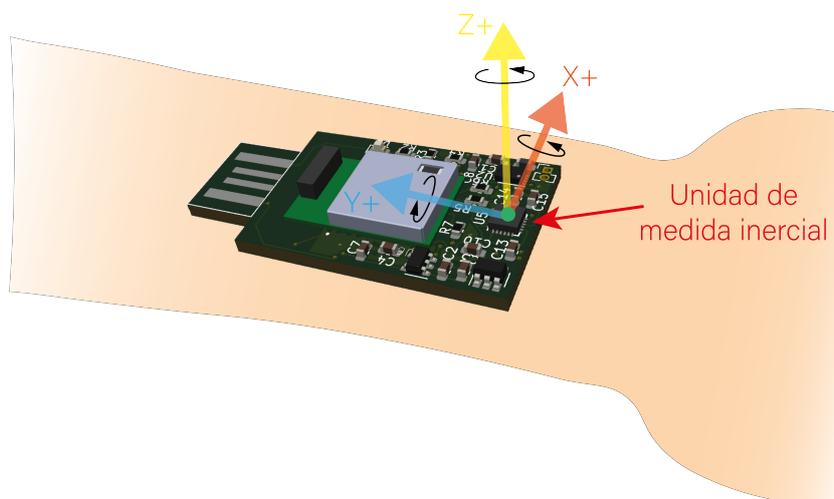


Figura 3.6: Recreación del posicionamiento del sensor de **AM** en el usuario.

3.3 CONTROL Y COMUNICACIÓN DEL DISPOSITIVO

El dispositivo de monitorización de bioseñales dispone de un microcontrolador que es el encargado de gobernar todas las funciones del sistema. Sobre éste corre un Sistema Operativo en Tiempo Real (**RTOS**), por sus siglas en inglés, el cual se encarga de adquirir la información de cada uno de los sensores que integra el dispositivo, realizar las conversiones necesarias y empaquetar la información. Además, el microcontrolador integra comunicación Bluetooth Low Energy (**BLE**) que le permite compartir toda la información con el dispositivo encargado de subir los datos a la base de datos remota donde se almacena toda la información recolectada. Cada uno de los sensores de medida dispone de un servicio y una característica **BLE** diferente a través de la cual se envía la información hasta el otro dispositivo.

En la Figura 3.7 se puede observar un diagrama de flujo con el ciclo de trabajo y las múltiples tareas ejecutadas en el microcontrolador. Como se muestra en el esquema, tras los procesos de inicialización del RTOS y de la pila de BLE, se realiza la configuración inicial de los diferentes sensores de medida y se crean las diferentes tareas encargadas de adquirir los datos de cada sensor. Una vez finalizada la etapa de inicialización, el dispositivo se muestra visible enviando anuncios de BLE a la espera de una conexión con el dispositivo central, el cual se encargará de la subida de datos (Sección 5.1). Cuando se establece la comunicación, cada una de las tareas asociada a cada sensor gestiona un temporizador con la frecuencia de muestreo de su sistema de medida. Cuando el temporizador se activa, la tarea se encarga de adquirir los datos del sensor y realizar las conversiones o filtrados necesarios. Finalmente, se actualiza el valor de la característica BLE correspondiente al sensor y se envía una notificación de cambio al dispositivo central. Si durante la ejecución de las tareas la comunicación BLE se pierde, el microcontrolador detiene las ejecución de las tareas y regresa al proceso de envío de anuncios BLE a la espera de enlazar nuevamente la comunicación con el dispositivo central.

3.4 GESTIÓN DE LA ALIMENTACIÓN

Un aspecto muy importante en un dispositivo de monitorización ambulatoria es la gestión de la alimentación y la autonomía de funcionamiento del sistema. El dispositivo se alimenta a partir de una batería de iones de litio 3,7 V de tensión nominal y 100 mAh de capacidad, con una dimensiones de 20x20x3 mm y un peso de 2,51 g. A partir de la tensión de la batería se extraen las diferentes tensiones necesarias para alimentar los sensores y los componentes del dispositivo mediante el uso de reguladores de tensión. Con esta configuración, el dispositivo tiene una autonomía de más de 24 horas de monitorización de manera continua.

Para el encendido y apagado del dispositivo, el sistema posee un circuito de protección que impide que el equipo se apague de manera errónea. El dispositivo posee un botón en la parte inferior, es decir, en la parte que coincide con el brazo del usuario, mediante el cual se enciende y apaga el dispositivo. Para encenderlo basta con una pulsación breve e inmediatamente el dispositivo avisará de que está encendido mediante un led de color azul que se ilumina. Sin embargo, para evitar que el dispositivo se apague de manera no deseada durante la monitorización, es necesario

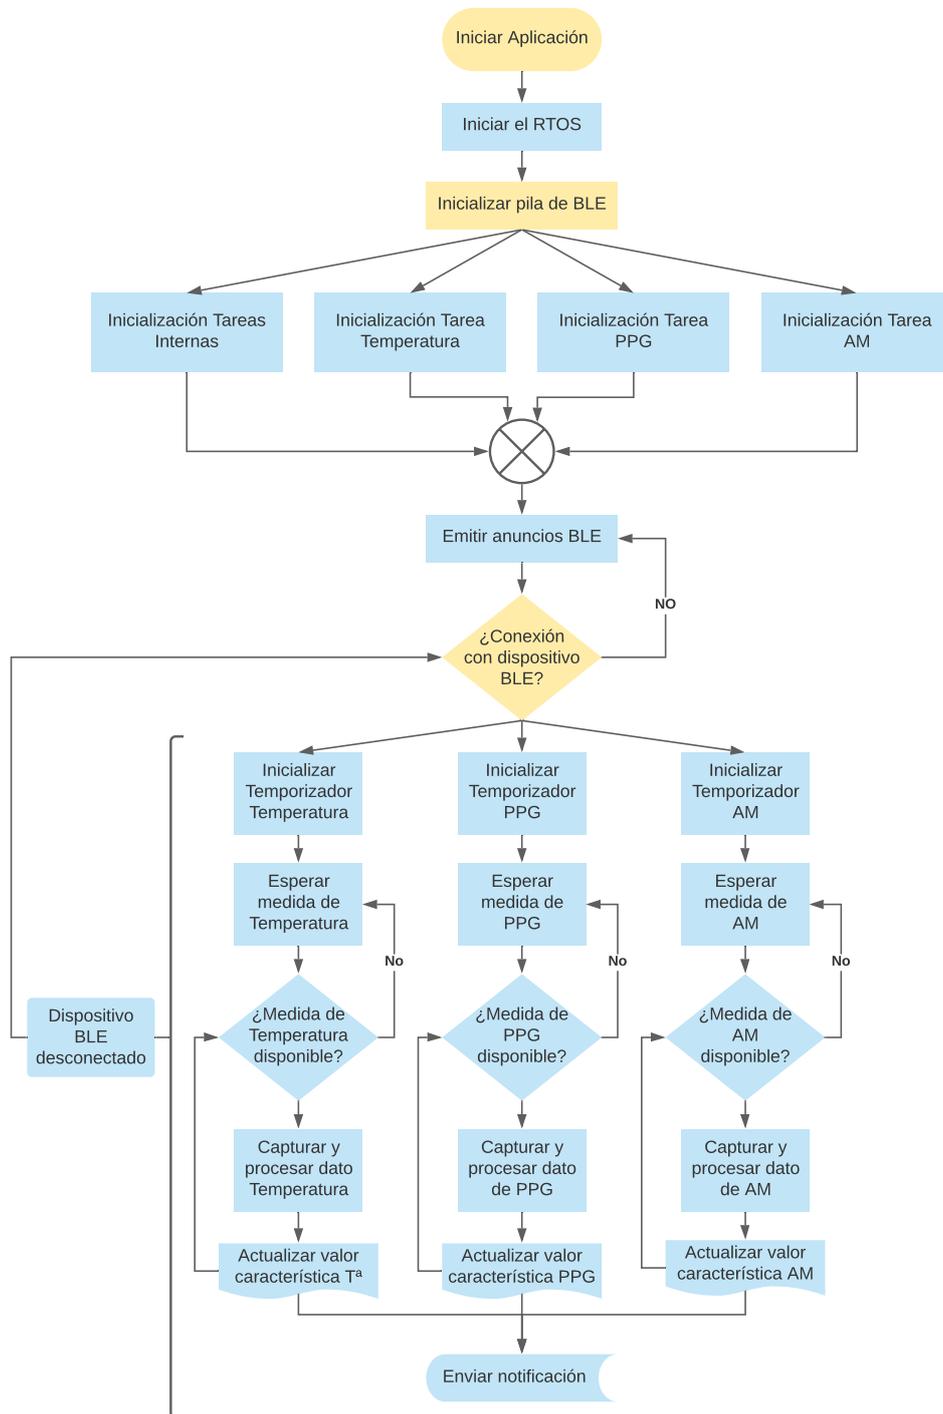


Figura 3.7: Flujo de trabajo del microcontrolador que controla el dispositivo de monitorización de bioseñales.

mantener pulsado el botón durante 8 segundos. Una vez alcanzado ese tiempo el led azul se apagará advirtiéndole de que el dispositivo está apagado.

Por último, el dispositivo tiene en uno de los extremos un conector USB Type-A macho impreso sobre la propia placa del dispositivo como podemos ver en la Figura 3.8. Este conector queda cubierto con la carcasa del dispositivo pero se mantiene un acceso fácil, para que el usuario a través de este conector y mediante el uso de un accesorio pueda cargar la batería del dispositivo.

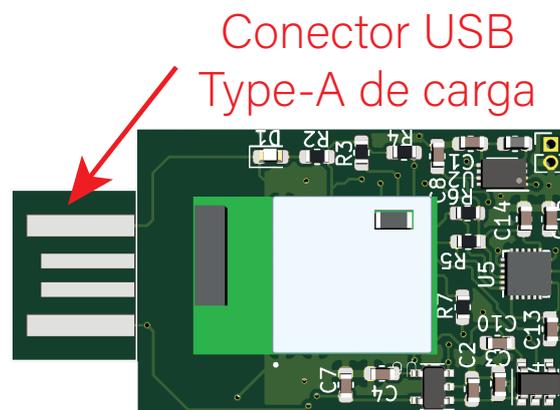


Figura 3.8: Imagen virtual del dispositivo de monitorización ambulatoria de bioseñales donde se aprecia el puerto USB Type-A impreso para la carga de la batería del dispositivo.

3.4.1 Accesorio para la carga de la batería

La carga del dispositivo se realiza a través del puerto USB Type-A macho impreso sobre la propia placa del dispositivo. Para ello es necesario utilizar un pequeño accesorio externo al que se conecta el dispositivo mediante dicho puerto. Este accesorio, con unas dimensiones de 45x26x16 mm y cuya carcasa se ha fabricado en impresora 3D, integra un gestor de carga para controlar el proceso de carga de la batería, limitar la corriente de carga hacia la batería, así como controlar que la temperatura de la batería no exceda los límites de seguridad.

En la Figura 3.9a se muestra una imagen virtual de la placa integrada en el accesorio de carga, mientras que en la Figura 3.9b se puede observar una fotografía real del accesorio de carga. El accesorio tiene en uno de los extremos un conector USB Type-A

hembra donde se conecta el dispositivo de monitorización. En el otro extremo dispone de un conector μ USB hembra donde se conecta mediante un cable a la salida de un transformador de 5V DC como los comúnmente utilizados para la carga de *smartphones*. En la parte superior, el accesorio dispone de un orificio a través del cual se pueden observar 3 leds para mostrar información sobre el proceso de carga (un led amarillo indica que el accesorio tiene tensión en su entrada de 5V; un led rojo indica que el dispositivo de monitorización está cargando; un led verde indica que el proceso de carga ha finalizado). La corriente de carga se ha limitado a un máximo de 60 mA, y el proceso de carga completa se demora en torno a 1 hora y media.

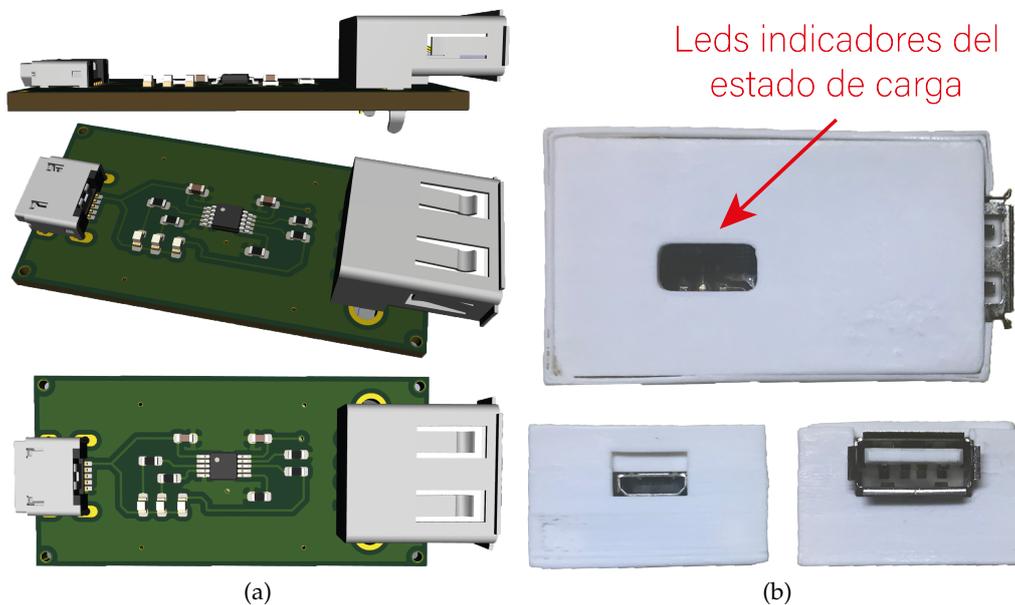


Figura 3.9: **(a)** Imagen virtual del accesorio para la carga de la batería. **(b)** Fotografía real del accesorio para la carga de la batería del dispositivo de monitorización de bioseñales.

3.5 FABRICACIÓN Y MONTAJE DEL DISPOSITIVO

El dispositivo de monitorización ambulatoria de bioseñales debe cumplir con una serie de requisitos en su diseño, los cuales fueron establecidos al principio de este capítulo. Entre estos requisitos, existen algunos relacionados con el acabado y los materiales que debe tener el dispositivo para que las personas con TEA, reacias al uso

de objetos extraños, puedan tolerarlo. Es por ello, que el dispositivo se ha montado sobre una carcasa de material suave y esponjoso que hace al sistema ergonómico y ligero.

Las partes principales que conforman el dispositivo para su montaje final son tres: por un lado la placa electrónica con todos sus componentes (sensores, microcontrolador, etc). Por otro lado la batería que alimenta al dispositivo. Y por último, una carcasa de goma Etilvinilacetato (EVA) que recubre la placa electrónica y la batería, además de formar la pulsera para fijar el dispositivo al usuario.

La carcasa está fabricada a partir de una lámina de goma EVA de 1,5 mm de espesor. En la Figura 3.10 se muestra la geometría de corte de la carcasa. La goma EVA se recorta utilizando un láser de corte que sigue el patrón del diseño mostrado, garantizando la precisión en las dimensiones de la funda. Las líneas discontinuas representan los puntos donde la funda debe flexionar para envolver la electrónica del dispositivo. Esto se realiza con un corte a menor potencia para que éste tenga poca profundidad en la goma EVA.

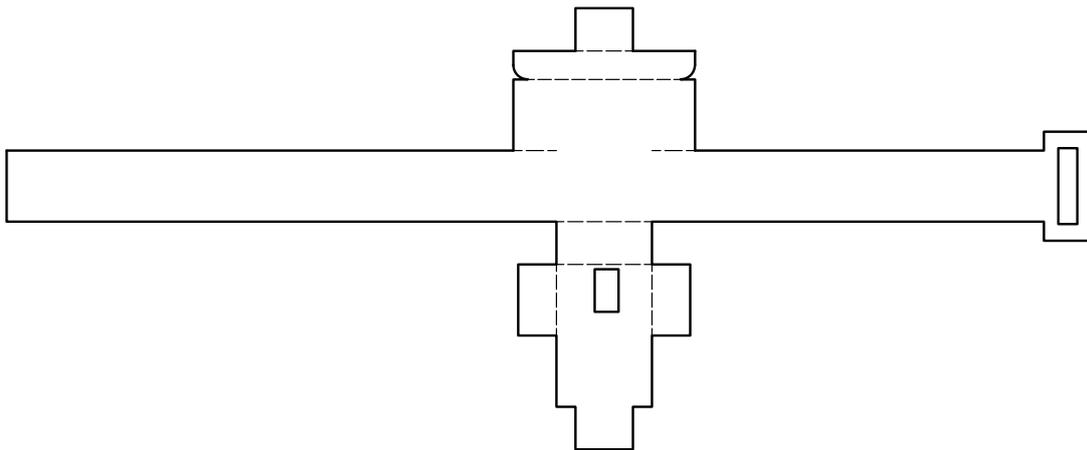


Figura 3.10: Geometría de corte de la carcasa para el dispositivo de monitorización de bioseñales.

La fijación entre la electrónica del dispositivo y la carcasa se realiza en primer lugar utilizando cinta adhesiva de doble cara. Una vez se envuelve la electrónica por completo y se da la forma apropiada, se sellan las juntas con cianoacrilato, disponiéndolo en las paredes que quedan cubiertas para evitar que se formen rugosidades al endurecer el pegamento. De esta manera, se construye el dispositivo con un material suave al tacto y muy ligero. El peso y las dimensiones finales del dispositivo con la carcasa son

de 5,90 gramos y 35x25x10 milímetros, mientras que las longitudes de la correa son personalizables según el usuario. En la Figura 3.11a se pueden ver las fotografías de un dispositivo finalizado y en la Figura 3.11b se observa como se ubica el dispositivo sobre la muñeca del usuario. Para fijar el sobrante de la correa de sujeción se utiliza una trabilla también fabricada con goma EVA.

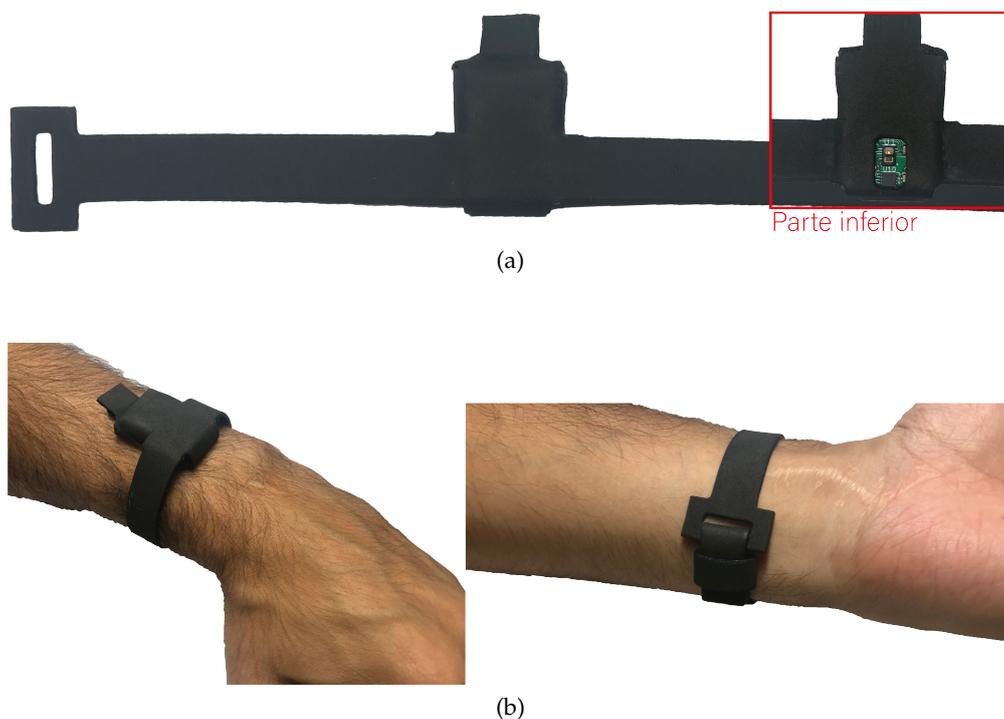


Figura 3.11: **(a)** Fotografía de un dispositivo de monitorización ambulatoria de bioseñales finalizado. **(b)** Fotografía del emplazamiento del dispositivo de monitorización en la muñeca del usuario.

3.6 CONCLUSIONES DEL CAPÍTULO

En este capítulo se ha presentado el diseño de un dispositivo de monitorización ambulatoria de bioseñales especialmente desarrollado para personas con TEA. Para ello, se han establecido en primer lugar una serie de requisitos que debe satisfacer el diseño.

Se han analizado las diferentes variables fisiológicas que se miden en el dispositivo y se han presentado los diferentes sensores para medirlas. También se explica la configuración utilizada para cada uno de los sensores y las conversiones o filtrados

que se realizan sobre cada una de las señales medidas. También se ha explicado el ciclo de trabajo del microcontrolador que gestiona el dispositivo de monitorización y la comunicación de éste con el dispositivo central, encargado de subir la información a la base de datos remota. Además, se ha analizado la gestión de la alimentación del sistema y se ha presentado el accesorio desarrollado para cargar la batería del dispositivo. Por último, se ha explicado la fabricación de la carcasa que cubre la parte electrónica y el proceso de montaje del dispositivo de monitorización.

DISPOSITIVOS DE MONITORIZACIÓN DEL ENTORNO

En este capítulo se presentan los diseños de dos dispositivos para la monitorización ambulatoria del entorno. La primera parte del capítulo está reservada para mostrar el diseño de un dispositivo de adquisición de las condiciones del entorno donde se encuentra el usuario. Se exponen los diferentes sensores integrados en el dispositivo, el control del sistema y la gestión de la alimentación, así como la fabricación y el montaje del dispositivo. La segunda parte del capítulo se presenta un dispositivo inteligente para la adquisición de estímulos visuales en el entorno donde se encuentra el usuario. Se describe la configuración del equipo, los diferentes procesos que realiza el dispositivo y el montaje del sistema. Por último, también se muestra el procedimiento empleado para el análisis del espectro de sonido en el entorno donde se encuentra el usuario.

4.1 DISPOSITIVO DE ADQUISICIÓN DE LAS CONDICIONES DEL ENTORNO

El primero de los dispositivos de monitorización del entorno es un sistema para medir las condiciones ambientales de la estancia donde se encuentra el usuario. Para poder llegar a establecer una relación entre los posibles cambios que se produzcan en el estado de la persona y los estímulos a su alrededor, es necesario conocer cuáles son los estímulos presentes en cada momento. Por ello, será necesario medir todos los estímulos ambientales presentes en torno al usuario.

Las condiciones ambientales de la estancia donde se encuentra el usuario son estímulos ambientales, y pueden beneficiar el confort de la persona o por el contrario favorecer una situación de incomodidad o molestia en la persona y volverla irascible. Las condiciones ambientales de la estancia no tienen que ser el determinante de una situación crítica en el comportamiento del usuario, pero sí pueden ser un aspecto que señale el límite de una persona frente a otro estímulo más significativo. Es decir, que una misma persona sea capaz de soportar cierto estímulo en unas condiciones ambientales favorables para él, mientras que en unas condiciones ambientales adversas no pueda tolerar ese mismo estímulo.

4.1.1 *Requisitos de diseño del dispositivo*

El dispositivo de monitorización de las condiciones ambientales no necesita estar en contacto con el usuario, y por tanto, no existe la exigencia de tener que adaptar el sistema a unas características especiales como sí ocurría con el dispositivo de monitorización de bioseñales (Capítulo 3). Sin embargo, si que es necesario atender a una serie de consideraciones a la hora de realizar su diseño.

Al contrario de lo que ocurría con el dispositivo de monitorización de bioseñales, el tamaño del sistema no es un problema dado que no tiene que situarse sobre el usuario. No obstante, el objetivo de este dispositivo es adquirir la información del lugar donde se encuentre el usuario y por ello, si el usuario se desplaza el dispositivo deberá desplazarse con él. En consecuencia, el dispositivo tiene que ser cómodo de transportar y poco pesado para que la persona encargada pueda moverlo cómodamente y no le suponga excesivo trabajo.

También es un aspecto importante en el diseño el formato final del dispositivo. Éste se tiene que situar en una zona lo más cercana posible al usuario dentro de la estancia pero donde no se vea tapado por otros objetos y no se tenga que mover constantemente de un lugar a otro. Así pues, debe tener una forma sencilla y que permita colocar el dispositivo con facilidad en cualquier entorno donde pueda ir el usuario. Además, debe de ser fácil de utilizar por la persona encargada de los cuidados del usuario.

4.1.2 *Sensores integrados en el dispositivo*

El dispositivo de adquisición de las condiciones del entorno es el encargado de medir las variables ambientales de la estancia donde se encuentra el usuario. Atendiendo al estudio expuesto en la sección 1.3, de las 11 variables seleccionadas para su inclusión en la plataforma, 8 de ellas han sido catalogadas como variables ambientales. Sin embargo, de estas 8 variables ambientales, este dispositivo de adquisición se encarga únicamente de medir las 4 que dependen exclusivamente de las condiciones ambientales de la estancia: la temperatura ambiente, la humedad relativa, la presión atmosférica y la luminosidad. Por lo tanto, el dispositivo integra diferentes sensores para medir estas propiedades.

4.1.2.1 *Sensor de temperatura ambiente y humedad relativa*

La temperatura ambiente y la humedad relativa afectan a los niveles de confort de las personas. Además, existe una relación entre ambas variables, y es que a medida que aumenta la temperatura el aire se vuelve más seco y por tanto, disminuye la humedad relativa. Por el contrario, cuando la temperatura del ambiente disminuye el aire se vuelve más húmedo, y la humedad relativa aumenta. Esto es debido a que la temperatura marca la presión de saturación del vapor de agua, es decir, la cantidad máxima de vapor de agua que puede contener el aire sin llegar a condensarse. Por tanto, la humedad y la temperatura elevadas implican más agua en el aire y esto permite por ejemplo, que el aire transporte las moléculas de olor más lejos, como ocurre en la época estival con las zonas donde hay basura, que al ser fuentes de bacterias desprenden un hedor considerable.

También es importante tener en cuenta la temperatura y la humedad cuando se practica deporte para evitar riesgos en la salud. El cuerpo humano depende de la evaporación del sudor para refrescarse y si el aire es muy caliente y húmedo, el cuerpo no puede ceder su calor a través de la evaporación del sudor, lo que puede provocar la deshidratación, un sobrecalentamiento e incluso la muerte ([Armstrong et al., 2019](#)). Además, existen estudios recientes que relevan la gran influencia de la temperatura y la humedad en la transmisión de virus como la gripe ([Mäkinen et al., 2009](#); [Lenglet et al., 2007](#); [Chan et al., 2011](#)). Asimismo, otros estudios también revelan el efecto de la temperatura y la humedad en la mortalidad por enfermedades cardiovasculares ([Hajat y Haines, 2002](#)). Una alta humedad afecta al riesgo de sufrir trombos, combinado con la respuesta del cuerpo humano ante el estrés provocado por el frío.

Para la medida de la temperatura y la humedad relativa el dispositivo de adquisición dispone de un sensor con salida digital (HDC1010 ([Instruments, 2016](#))). Se obtienen los valores de temperatura y humedad accediendo a los registros correspondientes, sin necesidad de realizar ningún procesamiento de señal. La frecuencia de muestreo del sensor se ha establecido a una medida cada minuto, ya que los cambios en la temperatura ambiente y la humedad relativa no son espontáneos. Únicamente cuando el usuario se desplace de un entorno a otro donde las condiciones ambientales sean diferentes se producirá un cambio brusco en las medidas. En la Figura 4.1 se muestran dos gráficas, una con la evolución de la temperatura ambiente y la otra con la evolución de la humedad relativa en la estancia durante una sesión de prueba.

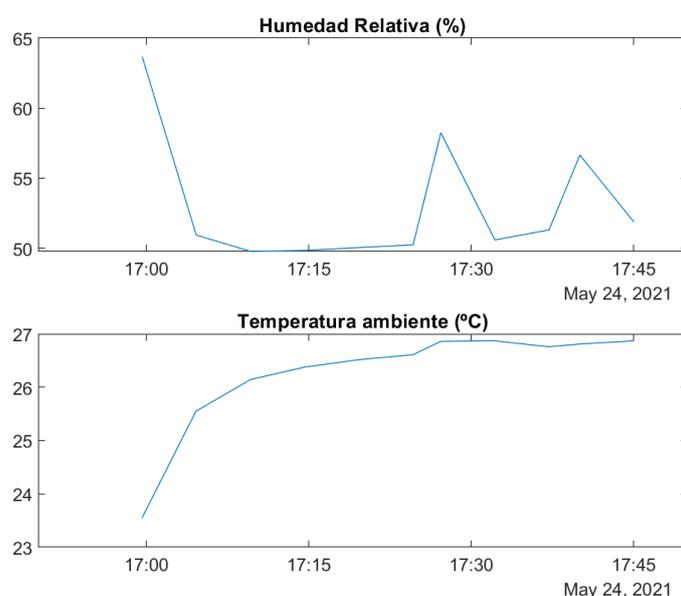


Figura 4.1: Gráficas de la evolución de la temperatura ambiente y la humedad relativa medidas con el sensor durante una sesión de prueba.

4.1.2.2 Sensor de presión atmosférica

La presión atmosférica es la fuerza por unidad de superficie ejercida por una columna atmosférica, es decir, toda la masa de aire sobre la superficie que se desea medir (Merriam, 1992). En apariencia, puede parecer que los cambios en la presión atmosférica no influyen en el comportamiento o en cambios en el estado del usuario, ya que son cambios muy lentos en el tiempo. De hecho, en el estudio presentado en la sección 1.3 se le asigna un valor de 0 en la columna de "Asignación clínica". Sin embargo, el valor de presión atmosférica si puede ser importante para determinar situaciones en las que el usuario puede sentirse incómodo, ya que cuando se mantienen períodos de baja presión, suele significar que el entorno que rodea al usuario está probablemente nublado e incluso con lluvia. Esta situación puede resultar molesta para la persona ya que el mal tiempo le impide poder salir a la calle o impedir seguir sus rutinas diarias y eso puede favorecer un mal comportamiento al sentirse atrapado. Además, al sentir que pierde el control puede volverse más impulsivo y provocar un aumento de la agresividad e incluso provocarle dolores en el cuerpo debido a la tensión. En definitiva, disminuir el nivel de optimismo y satisfacción del usuario provocando un cambio en su estado.

La medida de la presión atmosférica en el dispositivo de adquisición se realiza con un sensor de alta precisión también con salida digital que no requiere de procesamiento de señal (BMP280 (Bosch, 2020)). La frecuencia de muestreo del sensor se ha establecido en una medición cada minuto al igual que las dos variables anteriores (temperatura ambiente y humedad relativa), a pesar de que los cambios en la presión atmosférica son muy lentos en el tiempo y no varían bruscamente en los cambios de estancia como ocurre con la temperatura y la humedad, sino que dentro de una misma zona geográfica cercana serán valores prácticamente iguales. En la Figura 4.2 se muestra una gráfica de la evolución de la presión atmosférica medida con el sensor durante una sesión de prueba.

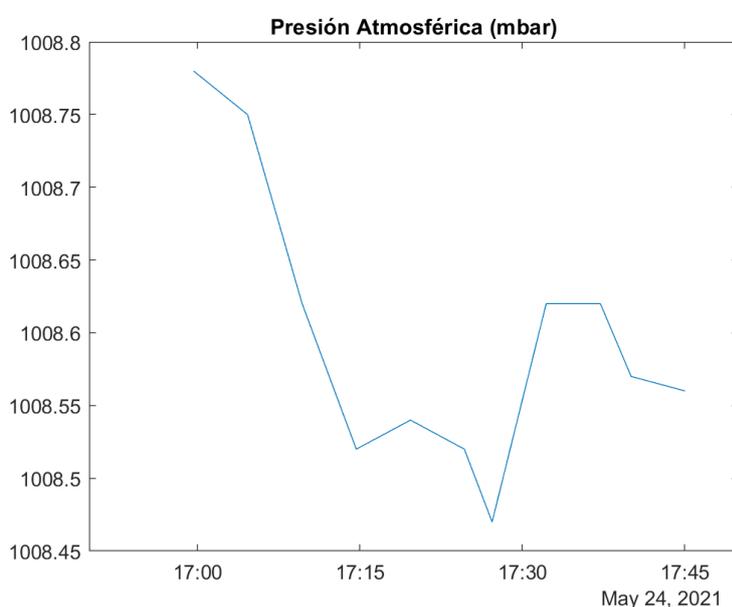


Figura 4.2: Gráfica de la evolución de la presión atmosférica medida con el sensor durante una sesión de prueba.

4.1.2.3 Sensor de luminosidad

La luminosidad es una variable muy importante para la plataforma porque las personas con TEA se ven afectadas generalmente por los cambios bruscos o con altas intensidades lumínicas. Las sensibilidades ópticas más frecuentes en las personas con TEA son a la luz brillante, a la luz fluorescente, al destello de los colores y a ciertos patrones, por ejemplo las rayas (Coulter, 2009). Los cambios de luminosidad al pasar por ejemplo de un entorno doméstico donde la luz mantiene unos niveles bajos, al

exterior donde la luz solar es muy alta y provoca además destellos en los objetos puede suponer molestia para una persona con fotosensibilidad o una sensibilidad óptica y sumado a otros posibles estímulos o una situación de ansiedad, estrés o fatiga previa puede suponer el desencadenamiento de una crisis en el usuario.

El sensor de luminosidad integrado en el dispositivo de adquisición es un sensor también con salida digital que mide la intensidad de la luz visible, es decir, la respuesta espectral del sensor se ajusta a la respuesta fotópica del ojo humano incluyendo el rechazo a los infrarrojos (OPT3001 (Instruments, 2017)). El sensor detecta intensidades lumínicas entre los 0,01 lux hasta los 83.000 lux, cubriendo incluso el rango de intensidad lumínica de la luz solar casi por completo (Michael et al., 2020). La frecuencia de muestreo del sistema se ha configurado en una medida cada diez segundos, dado que las personas con TEA pueden verse muy afectadas por los cambios de luminosidad, y de ese modo se intenta captar posibles destellos que aparezcan. En la Figura 4.3 se muestra una gráfica de la evolución de la luminosidad en la estancia medida por el sensor de luminosidad durante una sesión de prueba.

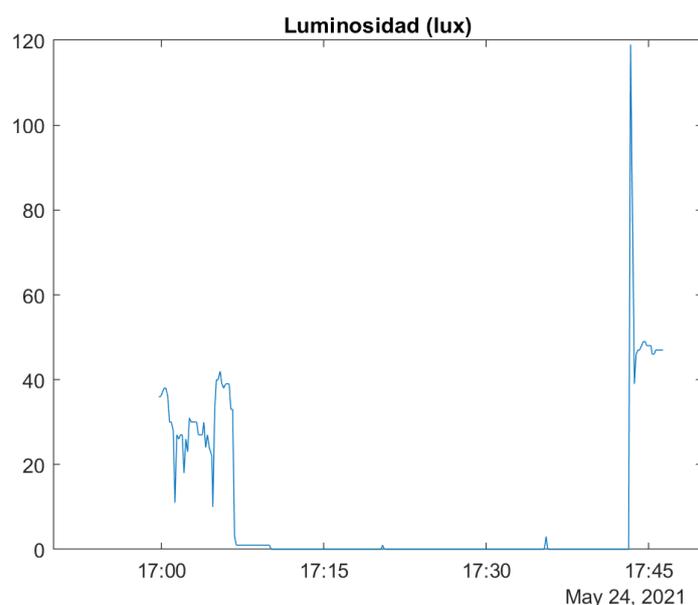


Figura 4.3: Gráfica de la evolución de la luminosidad de la estancia medida con el sensor durante una sesión de prueba.

4.1.3 Control y comunicación del dispositivo

El dispositivo de monitorización de bioseñales dispone de un microcontrolador que es el encargado de gobernar todas las funciones del sistema. Sobre éste corre un RTOS, por sus siglas en inglés, el cual se encarga de adquirir la información de cada uno de los sensores que integra el dispositivo, realizar las conversiones necesarias y empaquetar la información. Además, el microcontrolador integra comunicación BLE que le permite compartir toda la información con el dispositivo encargado de subir los datos a la base de datos remota donde se almacena toda la información recolectada. Cada uno de los sensores de medida dispone de un servicio y una característica BLE diferente a través de la cual se envía la información hasta el otro dispositivo.

En la Figura 4.4 se puede observar un diagrama de flujo con el ciclo de trabajo y las múltiples tareas ejecutadas en el microcontrolador. Como se muestra en el esquema, tras los procesos de inicialización del RTOS y de la pila de BLE, se realiza la configuración inicial de los diferentes sensores de medida y se crean las diferentes tareas encargadas de adquirir los datos de cada sensor. Una vez finalizada la etapa de inicialización, el dispositivo se muestra visible enviando anuncios de BLE a la espera de una conexión con el dispositivo central (Sección 5.1), el cual se encargará de la subida de datos. Cuando se establece la comunicación, cada una de las tareas asociada a cada sensor gestiona un temporizador con la frecuencia de muestreo de su sistema de medida. Cuando el temporizador se activa, la tarea se encarga de adquirir los datos del sensor y realizar las conversiones o filtrados necesarios. Finalmente, se actualiza el valor de la característica BLE correspondiente al sensor y se envía una notificación de cambio al dispositivo central. Si durante la ejecución de las tareas la comunicación BLE se pierde, el microcontrolador detiene las ejecución de las tareas y regresa al proceso de envío de anuncios BLE a la espera de enlazar nuevamente la comunicación con el dispositivo central.

El dispositivo de adquisición de las condiciones del entorno dispone de un microcontrolador al igual que el dispositivo de monitorización de bioseñales. Este es el encargado de ejecutar todas las funciones del sistema. Se trata del mismo microcontrolador y la ejecución del RTOS es exactamente la misma, como se puede observar en el diagrama de flujo de la Figura 4.4. Únicamente varía la configuración para los drivers de los diferentes sensores y los ciclos de trabajo de las tareas asignadas a cada uno de los sensores del dispositivo. Como ocurría en el dispositivo de monitorización de bioseñales, cada vez que la tarea de uno de los sensores obtiene un valor nuevo

medido por el sensor, envía a través de **BLE** una notificación al dispositivo central. La gestión de conexión y desconexión con el dispositivo central también se gestiona como en el dispositivo de monitorización de bioseñales, el sistema lanza anuncios esperando que el dispositivo central se conecte una vez inicializado el **RTOS**, la pila de **BLE** y las diferentes tareas de ejecución. Y si el dispositivo central se desconecta paraliza la ejecución hasta que se retoma la comunicación entre ambos dispositivos.

4.1.4 *Gestión de la alimentación*

El dispositivo de adquisición de condiciones del entorno es un sistema con un consumo de energía muy pequeño donde los diferentes sensores de medida tienen una frecuencia de muestreo muy baja y a penas consumen unos micro amperios durante el período de medida. Por lo tanto, no es necesario integrar un sistema de alimentación mediante batería, el cual implica un sistema de gestión de carga y además, la persona encargada de los cuidados del usuario debe estar pendiente de cargar otro dispositivo. Por ello, el dispositivo se alimenta a partir de una pila de botón **CR2032** de 3 V de tensión nominal y 225 mAh de capacidad. De la tensión de la pila se extraen los diferentes voltajes necesarios para la alimentación de los sensores y el microcontrolador. La autonomía del dispositivo con esta configuración alcanza el mes de uso.

Dado que se trata de un dispositivo donde se busca la facilidad de uso, para el encendido y apagado del sistema se integra un interruptor de dos posiciones en uno de los laterales. Para indicar el estado del dispositivo, se integra un led azul que se ilumina a través de la carcasa cuando el dispositivo se encuentra encendido.

4.1.5 *Fabricación y montaje del dispositivo*

Los requisitos para el diseño del dispositivo de adquisición de condiciones ambientales no son muy estrictos y por lo tanto se ha optado por una solución sencilla. El dispositivo está formado únicamente por la placa electrónica, la cual contiene todos los componentes necesarios (incluidos los sensores, el microcontrolador y el portapilas), la pila para alimentar el sistema y una carcasa de geometría rectangular. En la Figura 4.5 se muestra una recreación virtual de la placa electrónica por ambos lados, donde se puede observar el portapilas, el microcontrolador y los sensores del sistema.

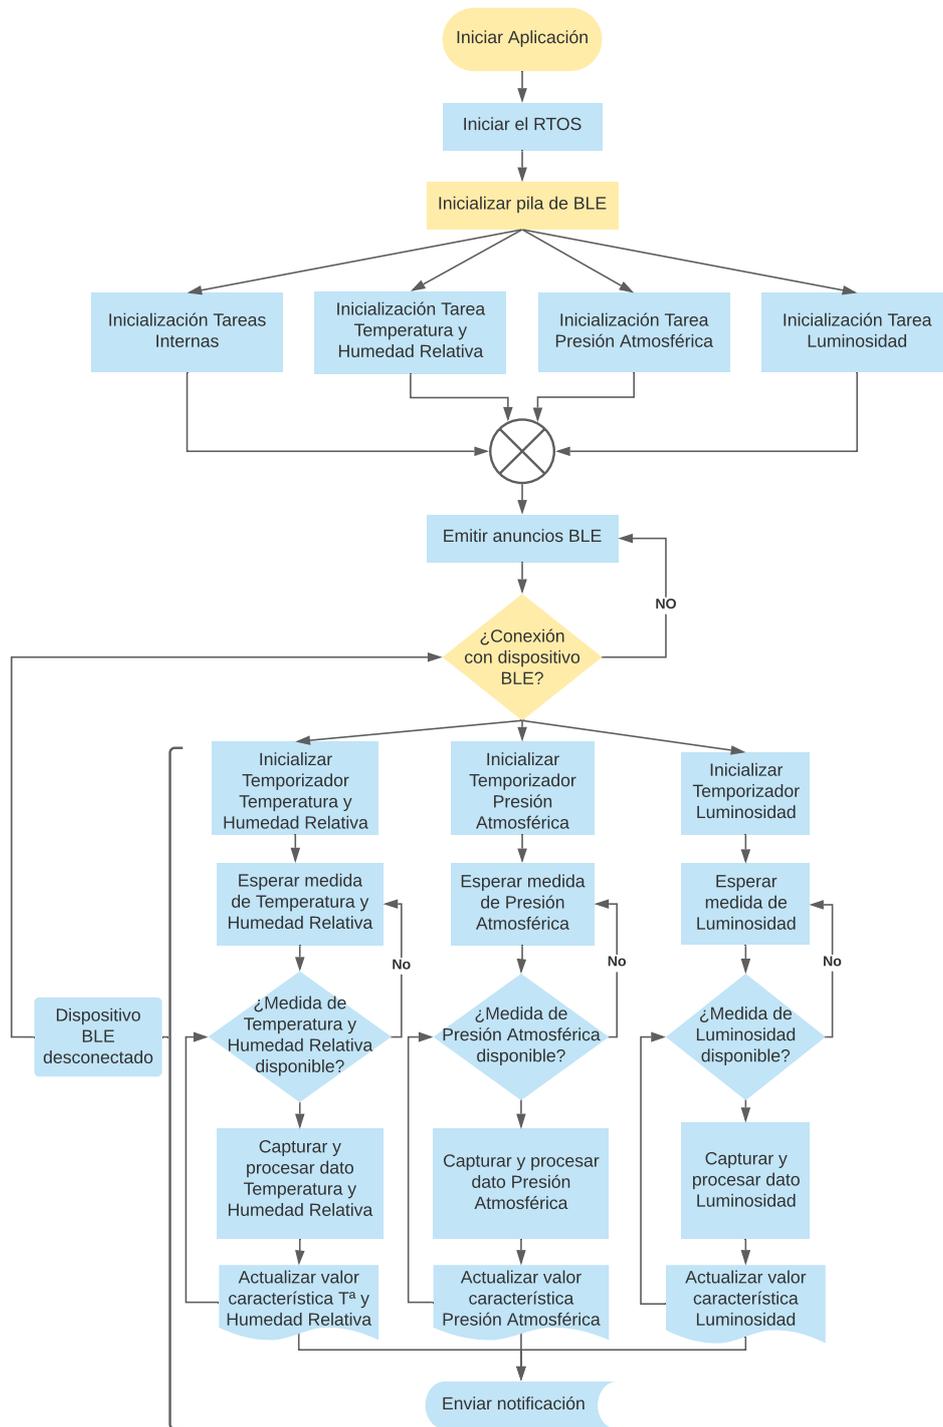


Figura 4.4: Flujo de trabajo del microcontrolador que controla el dispositivo de adquisición de condiciones del entorno.

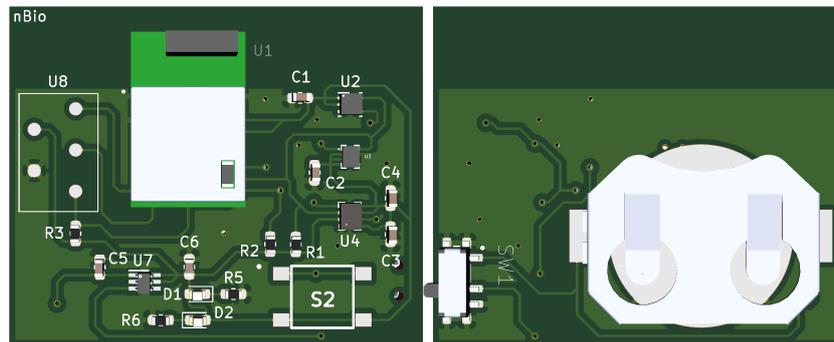


Figura 4.5: Imagen virtual de la placa electrónica que forma el dispositivo de adquisición de condiciones del entorno.

La carcasa está formada por dos piezas fabricadas en impresora 3D. La primera de ellas es una base rectangular con diferentes alturas internas donde se sitúa la placa electrónica con la pila insertada en el portapilas. La otra pieza es una tapa que protege el dispositivo y que cubre toda la parte superior a excepción de un pequeño orificio rectangular. Este hueco rectangular corresponde con la zona donde se sitúan los sensores de medida en la placa electrónica. Para obtener una medida correcta de las variables ambientales es necesario que los sensores tengan un contacto directo con el entorno y por ello se ha añadido esta apertura en la tapa. Finalmente, para permitir el acceso al interruptor de encendido del dispositivo, se ha dejado un espacio abierto en uno de los laterales, en la unión entre la dos piezas impresas, para poder deslizarlo.

En la Figura 4.6 se muestran las fotografías de un dispositivo de adquisición de condiciones del entorno montado. Las dimensiones finales del dispositivo son de 40x35x10 milímetros. En las fotografías se observan los huecos de la carcasa para los sensores y el interruptor de encendido. El formato resultante del dispositivo es similar al de un pequeño llavero y por lo tanto, es fácil de situar en una localización cercana al usuario para poder recolectar la información lo más parecida a las sensaciones que recibe la persona, sobretodo pensando en la luminosidad.

4.2 DISPOSITIVO DE ADQUISICIÓN DE ESTÍMULOS VISUALES

En esta sección se presenta un dispositivo inteligente para la monitorización de estímulos visuales. Se trata de un sistema capaz de obtener información visual relevante en el entorno donde se encuentra el usuario. Entre las variables seleccionadas para ser integradas en la plataforma, este dispositivo es el encargado de medir dos. La

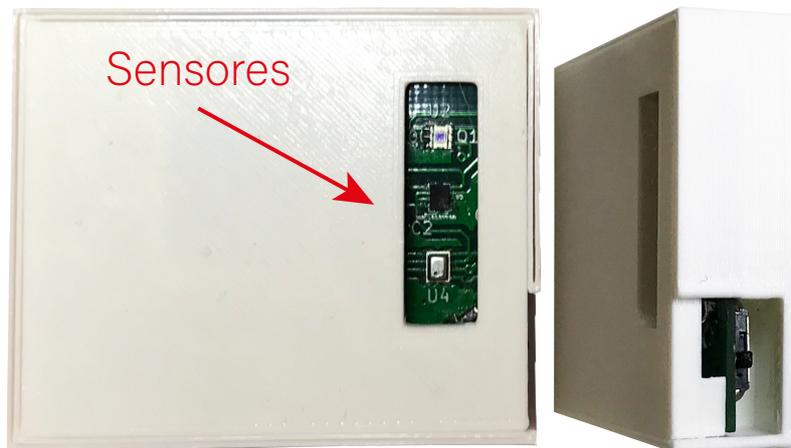


Figura 4.6: Fotografías de un dispositivo de adquisición de condiciones del entorno finalizado.

primera de ellas es la cantidad de personas que hay en el entorno, es decir, el número de personas que se hayan en la estancia alrededor del usuario. La otra variable es el ritmo o movimiento que se produce entorno al usuario.

Las personas con **TEA** tienen dificultades en la interacción social y éstas afectan a su bienestar social (Henry et al., 2016). Los estímulos que mide este dispositivo de monitorización son muy importantes para poder llegar a determinar la causa o una de las causas que provoque un cambio en el usuario en una determinada situación. Integrar este tipo de sistemas inteligentes dentro un sistema de monitorización ambulatorio es algo novedoso y por tanto, este sistema juega un papel muy valioso dentro de la plataforma.

4.2.1 *Requisitos del dispositivo*

Cuando se presenta el dispositivo de monitorización de estímulos visuales como un dispositivo inteligente es porque se trata de un sistema que se adapta, que aprende para mejorar la eficiencia y comprender la información o que es capaz de gestionar la información. En definitiva, un dispositivo que integra alguna inteligencia artificial o inteligencia computacional (Grosan y Abraham, 2011). Los sistemas de este tipo requieren de suficiente potencia computacional para obtener resultados en un tiempo mínimo. Para montar un dispositivo que trabaje en tiempo real proporcionando información, el sistema debe contar con un hardware que sea adecuado. Este tipo de sistemas suelen construirse sobre un ordenador potente que sea capaz de procesar

los algoritmos de manera rápida. Sin embargo, la finalidad del sistema presentado es desarrollar un dispositivo que sea ambulatorio, para acompañar al usuario allá donde esté. Por lo tanto, se debe encontrar una solución capaz de mover los algoritmos necesarios para obtener la información buscada pero que sea fácil de transportar.

Por otro lado, si lo que se desea medir son estímulos visuales será necesario capturar la información visual del entorno donde se encuentra el usuario. Para ello será indispensable emplear al menos una cámara posicionada en un punto adecuado de la estancia que capture todos los rincones del entorno, de manera que la información no sea incompleta. Dependiendo del tamaño del entorno o de la geometría de la estancia no siempre será posible obtener una información completa con una única cámara. Por tanto, se debe intentar encontrar una solución válida que sea conveniente para el sistema.

4.2.2 Configuración de hardware y software

El dispositivo de monitorización de estímulos visuales se ha desarrollado sobre una tarjeta de computación Nvidia Jetson Nano (Nvidia, 2021). La Nvidia Jetson Nano cuenta con una tarjeta gráfica que posee 128 núcleos CUDA[®] (Compute Unified Device Architecture), que se trata de una plataforma de computación paralela, los cuales favorecen la ejecución de aplicaciones donde se corren algoritmos de AA y algoritmos de visión por computador (Garland et al., 2008).

Sobre la tarjeta de computación corre un sistema operativo *Linux*, en el cual se ejecutan los diferentes algoritmos de AA y visión por computador. Además, también se encarga subir los datos obtenidos a la base datos remota a través del *Wifi "doméstico"* o el proporcionado por el dispositivo central (Sección 5.1) en un entorno externo. Para ello, emplea un driver de *Python* que gestiona la comunicación con la base de datos y se encarga de subir la información.

Para capturar la imagen del entorno se utiliza una cámara Insta360 Air, una cámara de 360 grados. Se ha optado por esta opción ya que la cámara de 360 grados posicionada en un lugar adecuado de la estancia y no muy alejada del usuario puede obtener información de toda el entorno, siempre y cuando no sean lugares excesivamente grandes.

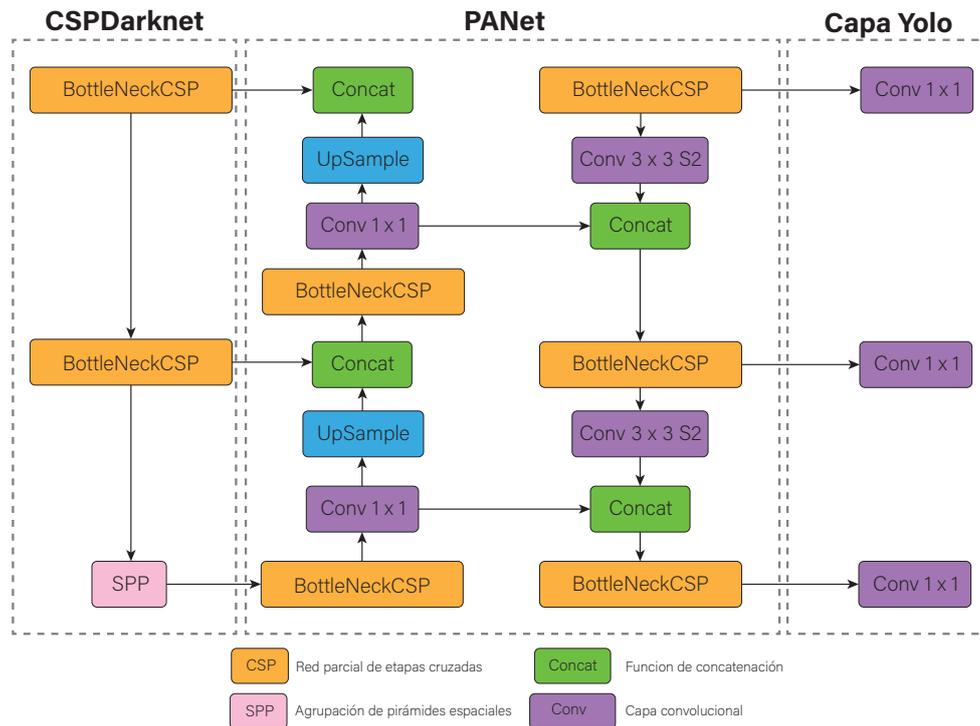


Figura 4.7: Arquitectura de redes de YoloV5.

4.2.3 Detección y cuantificación de personas

Los problemas en la interacción social es una de las principales peculiaridades de las personas con TEA. Cuando las personas con TEA se encuentran en un entorno con otras personas se pueden sentir incómodas, sobretodo si se trata de desconocidos. Una estancia con muchas personas, puede incrementar su sensación de agobio e incluso llegar a provocar una crisis al verse saturado. Si además pensamos en que un mayor número de personas suele acompañarle mayor nivel de voces y ruidos, controlar el número de personas alrededor del usuario es una variable muy importante para conocer su estado. Por lo tanto, la primera de las variables que mide el dispositivo de monitorización de estímulos visuales es el número de personas que hay en el entorno donde se encuentra el usuario en cada momento. De esta forma, la plataforma dispone de información que junto con otros parámetros permite relacionar entre otras cosas, por ejemplo, cómo puede afectar la interacción social al usuario o si una excesiva presencia de personas alrededor del usuario influye en su comportamiento (Autism, 2021).

Para poder cuantificar el número de personas presentes en cada instante, es necesario detectar a esas personas que se encuentran en el entorno. Es decir, el dispositivo necesita identificar las personas para poder cuantificarlas. La detección de personas se realiza mediante un modelo de redes neuronales profundas, que analizan cada uno de los fotogramas capturados por la cámara de 360 grados. Para ello, se emplea *YoloV5* (Bochkovskiy et al., 2020; Jocher et al., 2021), con un modelo preentrenado y optimizado para la detección de personas. Yolo es un detectos de objetos en tiempo real que permite trabajar con diferentes conjuntos de datos oficiales para detección de objetos. En este caso se ha optado por utilizar el conjunto *Microsoft COCO* (Common Object in Context) (T.-Y. Lin et al., 2014). En la Figura 4.7 se muestra la arquitectura interna de *YoloV5* implementada. Como se puede ver, *YoloV5* está formado por tres partes principales. En primer lugar está CSPDarknet, la unión de la red neuronal de etapas cruzadas *CSPNet* (C.-Y. Wang et al., 2020) y Darknet, un entorno de código abierto para redes neuronales, que se encarga de realizar la extracción de atributo. La segunda parte se corresponde con una red de agregación de rutas *PANet* (M. Wang et al., 2019) que se encarga de la fusión de los atributos extraídos. Por último, está la capa *Yolo*, que se encarga de dictar los resultados de la detección, como la clase de los objetos detectados, la ubicación de éstos, etc. El modelo tiene una alta velocidad en la ejecución realizando inferencia y su tamaño es contenido, lo que permite ejecutarlo en tiempo real en la tarjeta de computación Nvidia Jetson Nano. En la Figura 4.8 se muestra una captura de pantalla de un fotograma obtenido por la cámara donde se puede observar la detección de las personas en la estancia durante una sesión de pruebas. Se puede ver cómo la cámara de 360 grados recoge todo el entorno y el algoritmo identifica dónde se encuentran las personas. A partir de esa identificación se cuantifica el número de personas y se almacena el valor junto con la identificación temporal en la base de datos remota.

4.2.4 Cuantificación del flujo óptico

Independientemente del número de personas que haya en la estancia, algunas personas con TEA pueden sentirse igualmente agobiadas si hay una actividad excesiva a su alrededor, como movimientos constantes o cercanos al propio usuario. Además, estas acciones sumadas a otro estímulos, como por ejemplo el ruido ambiental, pueden verse intensificadas (Clark et al., 2020). Por ello, otra de las variables medidas por el dispositivo de monitorización de estímulos visuales es el flujo óptico.



Figura 4.8: Captura de pantalla de un fotograma analizado por el modelo de detección de personas.

El flujo óptico es el patrón de movimiento aparente de los objetos en la imagen entre dos fotogramas consecutivos, causado por el desplazamiento del objeto o de la cámara. Es decir, mide el cambio debido al movimiento entre dos fotogramas consecutivos capturados por la cámara. Se trata de un campo vectorial bidimensional donde cada vector representa un vector de desplazamiento que indica el movimiento de un punto desde su posición en el primer fotograma hasta su posición en el segundo fotograma (OpenCV, 2021). En consecuencia, si se mantiene la cámara en una posición fija dentro del entorno, el desplazamiento que se produce en la imagen entre fotogramas se deberá entonces sólo al movimiento de los objetos. En otras palabras, tendremos una estimación de cuánto movimiento se produce en el entorno del usuario.

Existen diferentes métodos para medir el flujo óptico. Para el dispositivo de monitorización de estímulos visuales se ha elegido una medición densa del flujo óptico, es decir, se calcula el desplazamiento de todos los puntos del fotograma. Para medir el flujo óptico de todos los puntos de la imagen y poder cuantificar el movimiento que se produce en el entorno del usuario, se utiliza el algoritmo de Gunnar Farnebäck (Farnebäck, 2003). Este algoritmo está basado en la expansión polinómica y realiza una estimación del movimiento denso entre dos fotogramas. Para integrar el algoritmo en el dispositivo se emplea la librería de visión por computador *OpenCV* (Bradski, 2000; OpenCV, 2021). El algoritmo devuelve el desplazamiento bidimensional de los objetos. Finalmente, se calcula el módulo de desplazamiento de ambos ejes y el resultado es el utilizado como variable de flujo óptico en cada instante. En la Figura 4.9 se muestra una gráfica de medición del flujo óptico durante una sesión de pruebas. Se puede

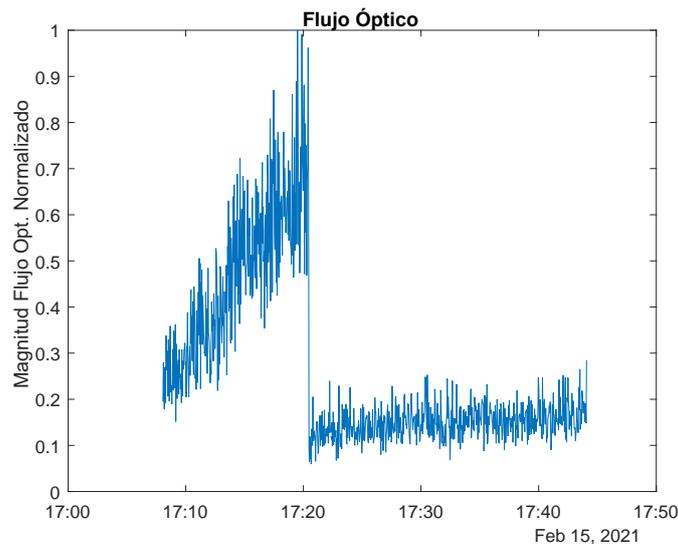


Figura 4.9: Gráfica de la evolución del flujo óptico medido durante una sesión de prueba.

observar cómo tras un periodo de tiempo el nivel de la señal es menor. Este hecho se debe a un cambio de posición de las personas presentes en la sesión a un lugar más alejado respecto de la cámara, lo que se traduce en un menor cambio medido entre los fotogramas y por tanto, en unos valores menores de magnitud en la señal.

4.2.5 Montaje y alimentación del dispositivo

El dispositivo está montado dentro de una carcasa de aluminio con unas dimensiones de 118x96x60 milímetros que lo protege. Dentro de la carcasa se ha instalado un kit de refrigeración mejorado para mantener la temperatura de la tarjeta de computación en rangos óptimos durante el funcionamiento del sistema, ya que la ejecución de los algoritmos, procesamiento de imagen y la inferencia, elevan la temperatura enormemente. En la Figura 4.10 se puede ver una fotografía del dispositivo de monitorización de estímulos visuales finalizado. La cámara de 360 grados se ha montado en la parte superior de la carcasa sobre una pletina de aluminio que la mantiene en una posición fija.

El sistema tiene unas dimensiones suficientemente reducidas como para que sea fácilmente transportable entre estancias. Con respecto a la alimentación del dispositivo, éste requiere de 5 voltios y 3 amperios de corriente continua para su funcionamiento por lo que se puede utilizar un transformador comercial común. Sin embargo, alimentar



Figura 4.10: Fotografía real del dispositivo de monitorización de estímulos visuales.

el sistema de una manera ambulatoria durante mucho tiempo no sería tan sencillo dado su consumo, pero mediante una *powerbank* se podría hacer funcionar el sistema durante posibles desplazamientos o estancias en el exterior donde no se dispone de alimentación.

4.3 ANÁLISIS DEL ESPECTRO DE SONIDO

Los problemas de sensibilidad al sonido o hiperacusia son muy habituales en personas con TEA (Stiegler y Davis, 2010). Por ejemplo, los niños con TEA a menudo se cubren los oídos con las manos o se sobresaltan ante un sonido moderadamente fuerte. Además, en ocasiones se suele sospechar de pérdida de audición en niños pequeños con TEA cuando suele ser debido a una falta de capacidad de comunicación, un retraso en el desarrollo del habla y el lenguaje corporal o a la hiperacusia ante ciertos estímulos auditivos (Danesh y Kaf, 2012). En ocasiones no es el impacto de un sonido fuerte el que afecte al usuario, sino que determinadas frecuencias pueden afectar más que otras a la persona. Por ello, la importancia de incluir un sistema de medida de los estímulos sonoros en la plataforma que analice el espectro auditivo, resulta imprescindible para disponer de información que pueda relacionarse con los cambios en el estado del usuario.

El sistema para el análisis de los estímulos sonoros puede ser integrado en cualquiera de los dispositivos de monitorización previamente presentados. Sin embargo, no se ha instalado en el dispositivo de monitorización de estímulos visuales dado que este dispositivo puede no ser utilizado en ciertas ocasiones, ya sea debido a los requisitos de alimentación o simplemente porque la persona encargada de los cuidados del usuario decida prescindir de su uso en ciertos entornos donde considera que no aporta información relevante, como por ejemplo en un paraje natural, dando un paseo en un lugar tranquilo o practicando algún juego o actividad deportiva. Por lo tanto, el análisis del espectro de sonido se ha integrado en el dispositivo central (Sección 5.1), el cual se encarga de la gestión de los dispositivos de monitorización, personal y ambiental, y de subir la información a la base de datos remota. Este dispositivo siempre debe ir con los dispositivos de monitorización y por tanto estará presente en cualquier entorno. Además, se puede situar en un lugar adecuado donde capte adecuadamente el ruido del entorno.

El análisis del espectro de sonido se realiza con el micrófono del dispositivo central, un smartphone, y con ayuda de la librería *TarsosDSP* (Six et al., 2014) para procesamiento de audio, que funciona en el lenguaje *Java*.

En primer lugar, se realiza una captura a través de un servicio de audio que recoge el espectro sonoro entre los 60 Hz y los 20 kHz, el cual es el rango de valores óptimos de funcionamiento del micrófono digital. Para la captura se utiliza una tasa de muestreo en el servicio de 44100 Hz, lo que permite capturar cualquier sonido dentro del espectro audible humano (entre los 20 Hz y los 22 kHz), y un tamaño del búfer de 2048.

A continuación, se calcula la *FFT* de la señal almacenada en el búfer y se computa el módulo de los diferentes contenedores devueltos como resultado de la *FFT*. Posteriormente, se aplica el filtro de ponderación *A* (*Electroacoustics-Sound Level Meters-Part 1: Specifications 2013*) a las magnitudes calculadas. Y después, se separan los contenedores en octavas (*Acoustical Terminology 2013*).

Cada una de las octavas almacena información de un rango de frecuencias. Estos rangos se han calculado para una octava completa y 10 bandas. En la Tabla 4.1 se muestra la división de las diferentes octavas, junto con las frecuencias inferior, central y superior de cada una de las bandas. Las bandas 0, 1 y 2 se han fusionado en una sola banda porque la energía contenida en frecuencias muy bajas es pequeña debido al rango de funcionamiento del micrófono.

Una vez dividida la información en octavas, se calcula la energía acumulada de cada banda con el *Teorema de Parseval* (Arfken et al., 2013). Los valores de cada octava, en dB-A, se almacenan en una lista o vector diferentes. Cada 10 segundos se calcula la media y la varianza de cada vector de octava y los resultados se guardan en un vector final de forma ordenada. Este vector es el resultado buscado para el proceso de audio. La información se almacena en la base de datos remota. En la Figura 4.11 se muestra una gráfica con el análisis del espectro de sonido en la estancia durante una sesión de prueba.

Tabla 4.1: División de las bandas de Octavas.

Número Banda	Límite inferior Banda (Hz)	Frecuencia Central (Hz)	Límite superior Banda (Hz)	Rango de Contenedores
0	22	31.5	44	0 - 0
1	44	63	88	1 - 2
2	88	125	177	3 - 6
3	177	250	355	7 - 14
4	355	500	710	15 - 30
5	710	1000	1420	31 - 62
6	1420	2000	2840	63 - 126
7	2840	4000	5680	127 - 254
8	5680	8000	11360	255 - 510
9	11360	16000	22720	511 - 1023

4.4 CONCLUSIONES DEL CAPÍTULO

En este capítulo se han presentado dos dispositivos de monitorización que forman parte de la plataforma. El primero de ellos es un dispositivo para la adquisición de las condiciones ambientales del entorno. Este dispositivo de reducidas dimensiones se sitúa cerca del usuario y recolecta información sobre las condiciones de la estancia.

El segundo de los dispositivos es un sistema para la monitorización de estímulos visuales. Concretamente, este dispositivo identifica las personas que hay en el entorno en cada instante y las cuantifica. Además, también cuantifica el flujo óptico en la estancia, es decir, mide la cantidad de movimiento de los objetos que hay en el entorno,

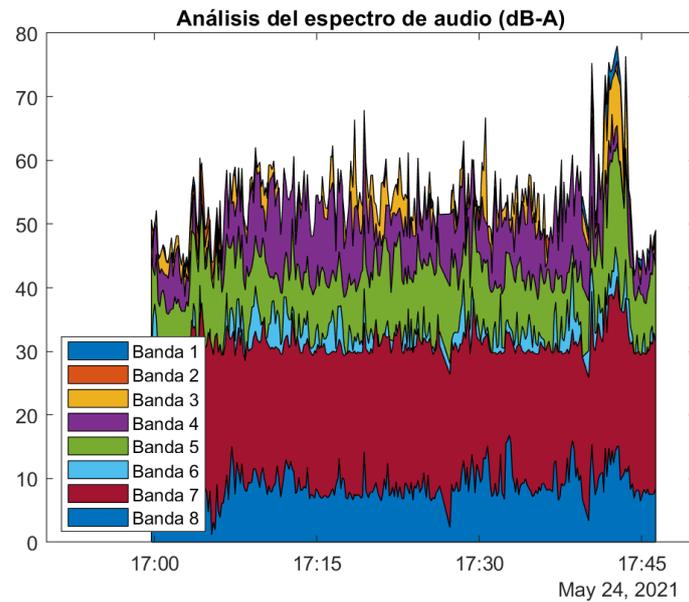


Figura 4.11: Gráfica del análisis del espectro de sonido medido por el sensor durante una sesión de prueba.

incluidos los movimientos de las personas. Para el desarrollo de estos algoritmos se han utilizado herramientas de [AA](#) y de visión por computador.

Por último, también se ha presentado el proceso para realizar un análisis del espectro de sonido del entorno.

GESTIÓN DEL SISTEMA Y ALMACENAMIENTO DE LA INFORMACIÓN

En este capítulo se presenta el dispositivo encargado de la gestión de los dispositivos de monitorización personal y ambiental, así como de la subida de la información recolectada por estos a la base de datos remota. En primer lugar se muestra el desarrollo y la arquitectura de la aplicación integrada en el dispositivo, al igual que el proceso de comunicación entre el dispositivo y la base de datos. Después se expone la arquitectura de la base de datos, cómo se almacena cada una de las variables de la plataforma y como acceder a la información almacenada en ésta. Por último, se muestra un ejemplo de generación de gráficos en tiempo real de la información almacenada en la base de datos.

5.1 DISPOSITIVO DE GESTIÓN DEL SISTEMA

En esta sección se presenta el último de los dispositivos utilizados en la plataforma desarrollada en la presente tesis. Se trata de un dispositivo encargado de gestionar los sistemas de monitorización de bioseñales y de adquisición de condiciones del entorno. Además, este dispositivo también es el encargado de subir la información a la base de datos remota y de mostrar información relevante al usuario o a la persona encargada de sus cuidados.

Este dispositivo consiste en un smartphone *Android* con comunicación [BLE](#) integrada. Para ello, se ha desarrollado una aplicación *Android* propia, cuyo nombre se ha establecido "*Pangea*", instalada en el smartphone que desempeña todas las tareas necesarias. A través de esta aplicación se controla la comunicación [BLE](#) con los dispositivos de monitorización, se obtiene el estado de la batería de éstos, se muestra información visual sobre los datos recolectados, se sube la información recolectada a la base de datos, y además, también se realiza el análisis del espectro de sonido expuesto en la Sección [4.3](#). Adicionalmente, el smartphone también proporciona un punto de

red *Wifi* cuando se utiliza el dispositivo de monitorización de estímulos visuales en el exterior, sin una conexión *Wifi* "doméstica" disponible a través de los datos móviles.

Al inicializar la aplicación *Android*, ésta busca si los dispositivos de monitorización se encuentran disponibles, es decir, si están enviando anuncios *BLE* a la espera de una conexión. Cuando la aplicación encuentra los dispositivos y establece la comunicación, realiza una búsqueda de los diferentes servicios asignados a cada variable (frecuencia cardíaca, luminosidad, etc). Cada vez que encuentra uno de estos servicios, habilita la recepción de notificaciones en su característica de valor de medida correspondiente, para poder recibir notificaciones por parte del dispositivo de monitorización al cual pertenece. Estas notificaciones se envían desde el dispositivo periférico cada vez que el valor de la característica cambia con una nueva medida realizada por el sensor. Además de habilitar la recepción de notificaciones, al descubrir el servicio también envía al microcontrolador del dispositivo periférico correspondiente la orden de comenzar la tarea de lectura por parte del sensor asignado a la variable.

Cuando la aplicación mantiene una conexión con al menos uno de los dispositivos periféricos (personal o ambiental), los procesos y servicios de la aplicación se mantendrán en ejecución incluso en segundo plano durante tiempo indefinido, impidiendo así que se detenga involuntariamente la recogida de información. De modo que para detener la aplicación es necesario desconectar antes los dispositivos de monitorización. Por otro lado, el servicio encargado de realizar el análisis del espectro de sonoro se habilita únicamente cuando la aplicación mantiene activa la conexión con el dispositivo de adquisición de condiciones ambientales. De ese modo, el análisis del sonido irá vinculado a un análisis completo de las condiciones del entorno.

Cada 25 segundos los dispositivos periféricos envían información sobre su nivel de batería a la aplicación central a través de una característica *BLE* perteneciente a un servicio creado para el estado de la batería. Esto permite mostrar información sobre los niveles de batería al usuario o a su cuidador y poder cargar el dispositivo de monitorización de bioseñales cuando sea necesario y adecuado.

La aplicación desarrollada dispone de múltiples variantes y es adaptable según el objetivo que se desee desarrollar con el uso de la plataforma. Por ejemplo, es posible almacenar la información de las variables de manera local si se desea, establecer alertas que pueden ser útiles para determinadas variables como la frecuencia cardíaca o la temperatura corporal y ajustar las frecuencias de muestreo de los sensores desde la propia aplicación. Sin embargo, la mayoría de estas funciones están pensadas para un uso experimental durante los períodos iniciales de recogida de datos con un nuevo

usuario, permitiendo adaptar el sistema a la condiciones del usuario. También es aplicable la definición de adaptable o personalizada a la interfaz gráfica de usuario (Subsección 5.1.1).

5.1.1 Interfaz gráfica de usuario

La interfaz gráfica de usuario o GUI, por sus siglas en inglés, es el recurso para interactuar entre el software desarrollado en la aplicación *Android* y el usuario o la persona encargada de sus cuidados. Es decir, es la información y los botones que se muestran en la pantalla del smartphone durante la ejecución de la aplicación desarrollada. Tanto la estructura de la interfaz como la información que se muestra por pantalla es totalmente personalizable y por tanto, dependerá del uso que se le vaya a dar a la plataforma.

Cuando el sistema esté siendo utilizado para obtener información experimental por parte de personal clínico o personal especializado en el desarrollo de los sistemas utilizados, las opciones disponibles así como la información que se muestre será muy diferente respecto a cuando el uso sea por parte de los padres o del cuidador de una persona con TEA en un entorno doméstico. Por ejemplo, en la Figura 5.1 se muestra una captura de pantalla de una de las interfaces diseñadas para las pruebas realizadas en entorno doméstico, donde la recogida de información ha sido desempeñada por parte de padres de niños con TEA. Se trata de una interfaz con información básica que permite al usuario comprobar el correcto funcionamiento del sistema. La interfaz muestra el estado de conexión de los dispositivos de monitorización, personal y ambiental, y los últimos valores medidos por el sistema de algunas de las variables de la plataforma. En este caso, no se muestra información sobre el sonido o la actividad motora ya que la información no es fácil de interpretar o requiere de un procesamiento posterior. En la interfaz dispone también de un botón que permite al usuario introducir información en cualquier momento. Presionando sobre el botón "*Activity*" aparece un cuadro de texto donde se puede escribir la información que se desee y que puede ser por ejemplo, el inicio o final de una actividad que realiza el niño o una aclaración acerca del estado del niño si ha sufrido una crisis. Además, la aplicación avisa de la desconexión de los dispositivos de adquisición si fuera necesario, así como la pérdida de la conexión a internet para subir los datos a la base de datos remota.

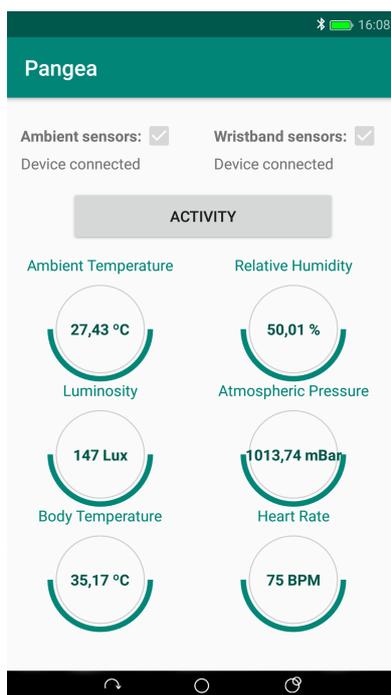


Figura 5.1: Captura de pantalla de la interfaz gráfica de usuario de la aplicación *Android* diseñada para uso doméstico.

5.1.2 Comunicación dispositivo central - base de datos

El dispositivo central recibe una notificación **BLE** cada vez que una característica vinculada a la medida de una variable cambia su valor. En ese momento y de manera automática solicita al dispositivo periférico correspondiente el nuevo valor de la característica. El valor recibido es procesado si es necesario, y se dispone de una manera organizada para subir la información a la base de datos remota.

Cuando el dispositivo necesita subir información, la aplicación *Android* se conecta a la base de datos a través de un driver para *Java* que gestiona la comunicación a través de internet mediante una conexión protegida con seguridad **TLS** (*Transport Layer Security* o seguridad de la capa de transporte) con algoritmos de cifrado para codificar la información compartida en la conexión entre ambas partes (Blake-Wilson et al., 2003). El driver establece la comunicación mediante una cadena de conexión que identifica la dirección a la base de datos correspondiente, el protocolo de identificación, las credenciales y una serie de parámetros opcionales para la conexión.

Una vez establecida la comunicación entre el dispositivo y la base de datos, la aplicación puede subir la información recolectada por los sensores a ésta. Para ello, los datos deben organizarse dentro de un documento *JSON* (JavaScript Object Notation, por sus siglas en inglés) binario o también llamado *BSON*. Se trata de un formato de texto sencillo para el intercambio de datos, que representa estructuras de datos y mapas (Pezoa et al., 2016). Consiste en una lista ordenada de elementos donde cada elemento está compuesto por un nombre, un tipo de dato y el valor de ese atributo. Una vez la información está organizada dentro del archivo, la aplicación sube éste mediante el driver y la base de datos interpreta la información y la almacena en su lugar correspondiente.

5.1.2.1 Organización de las variables en documentos *BSON*

La información obtenida con cada una de las variables medidas en la plataforma es diferente. Sin embargo, para la organización de los documentos *BSON* se ha establecido una configuración primitiva sobre la cual se adapta a cada una de ellas. Cada documento incluye un total de cuatro atributos. El primer atributo se llama *_id* y es un identificador de tipo *ObjectId* de 12 *bytes* único, cuyo valor lo establece automáticamente la base de datos al subir el documento, e identifica a éste. El segundo de ellos, es un atributo llamado *date*, cuyo tipo es numérico y en él se almacena el *timestamp* o marca temporal con la medición en milisegundos desde 1970, es decir el *Tiempo Unix* o *POSIX*, de la medida. El tercero de los atributos, *dateString*, también indica la fecha de la medida pero en cadena de caracteres. Por último, el cuarto atributo es en el cual se almacena la información de cada medida tomada por los sensores y cuyo nombre y tipo dependen de cada variable. A continuación se listan las estructuras de los documentos *BSON* tipo de cada una de las variables integradas en la plataforma.

■ Temperatura corporal

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "bodytemperature":NumberDecimal
}
```

■ Frecuencia cardíaca

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "heart":NumberDecimal
}
```

■ Actividad motora

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "motor":[gyrX,gyrY,gyrZ,accX,accY,accZ,magX,magY,magZ]
}
```

■ Temperatura ambiente

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "temperature":NumberDecimal
}
```

■ Humedad relativa

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "humidity":NumberDecimal
}
```

- **Presión atmosférica**

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "pressure":NumberDecimal
}
```

- **Luminosidad**

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "luminosity":NumberDecimal
}
```

- **Cuantificación de personas**

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "person":NumberInt
}
```

- **Flujo óptico**

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "optical":NumberDecimal
}
```

■ Sonido

```
{
  "_id":ObjectId
  "date":NumberLong
  "dateString":"EEE MMM d HH:mm:ss z yyyy"
  "sound":[a1,v1,a2,v2,a3,v3,a4,v4,a5,v5,a6,v6,a7,v7,a8,v8]
}
```

5.2 ALMACENAMIENTO DE LA INFORMACIÓN

La información recolectada por los sensores en cada uno de los dispositivos de monitorización se almacena en una base de datos remota que permite acceder a ella desde cualquier parte y en cualquier momento. Además, la información debe estar organizada de manera eficiente y segura. Por tanto, la base de datos debe cumplir con algunos requisitos que permitan que la plataforma funcione correctamente y con tiempos mínimos de ejecución. A continuación se enumeran las principales propiedades que debe cumplir la base de datos empleada.

- Debe permitir la integración de múltiples tipos de datos, así como permitir cambiar fácilmente la arquitectura de almacenamiento de la información si es necesario.
- Debe mantener una disponibilidad continua y escalabilidad de los datos.
- Debe soportar series temporales. Esto requiere menos espacio de almacenamiento y permite una mayor velocidad en las consultas de datos.
- Debe realizar actualizaciones continuas de los datos que permitan un análisis de la información en tiempo real.
- Debe tener fuertes controles de acceso, auditorías de datos y proteger los datos con controles de encriptación. La información almacenada en la base de datos es muy valiosa para el usuario y para la propia plataforma. Por lo tanto, hay que cumplir con las normas de seguridad que garanticen el anonimato de los datos y la restricción a su acceso.

La base de datos utilizada en la plataforma es una base de datos no relacional (NoSQL) de tipo documental llamada *MongoDB* (MongoDB, 2021). *MongoDB* es una base de datos distribuida, basada en documentos de tipo *BSON* diseñada para aplicaciones

y para su uso en el internet de las cosas y la era de la computación en la nube. Esta base de datos cumple con los requisitos planteados y aporta una serie de herramientas para el desarrollo y la puesta en marcha de aplicaciones que facilitan el trabajo de la plataforma.

5.2.1 Estructura de almacenamiento

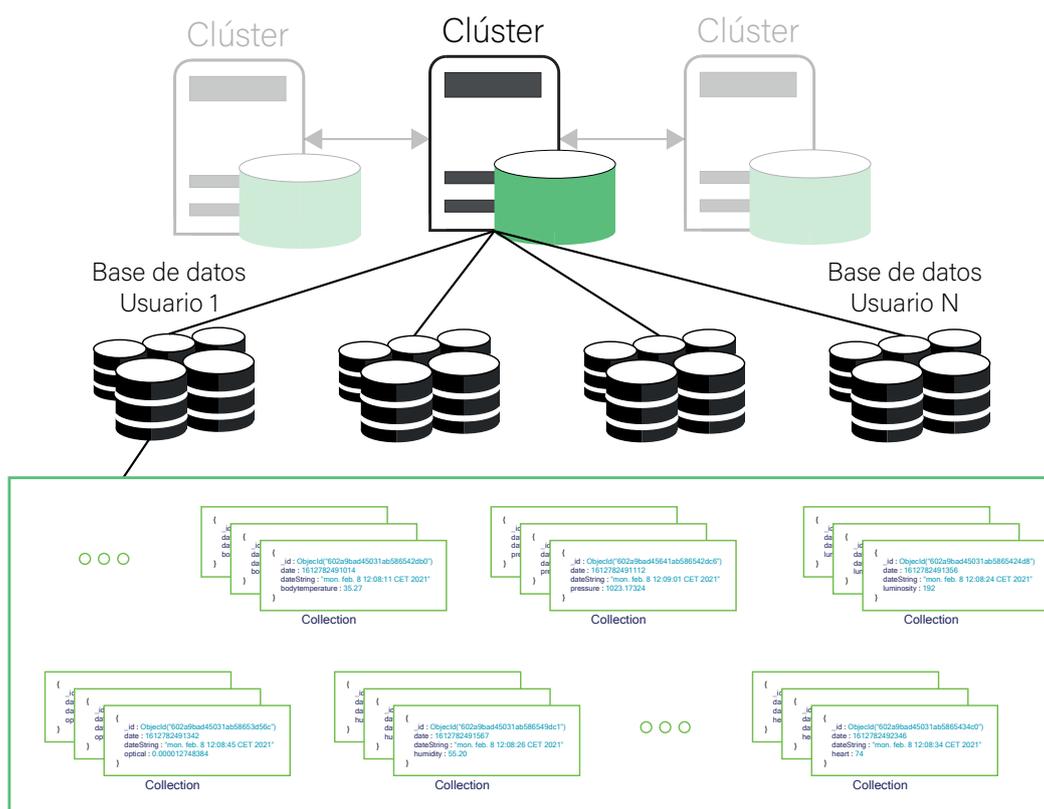


Figura 5.2: Mapa conceptual de la arquitectura de almacenamiento de la información.

Los datos almacenados dentro de *MongoDB* están almacenados en documentos. Cada uno de los documentos corresponde a una medida de una variable. Todos los documentos de cada una de las variables se almacenan dentro de una colección de datos, es decir, existe una colección de datos diferente para cada parámetro medido. Esto permite integrar nuevos parámetros en la plataforma fácilmente sin la necesidad de modificar la arquitectura de almacenamiento. Estas colecciones de datos a su vez se almacenan en una base de datos. Existe una base de datos particular para cada usuario

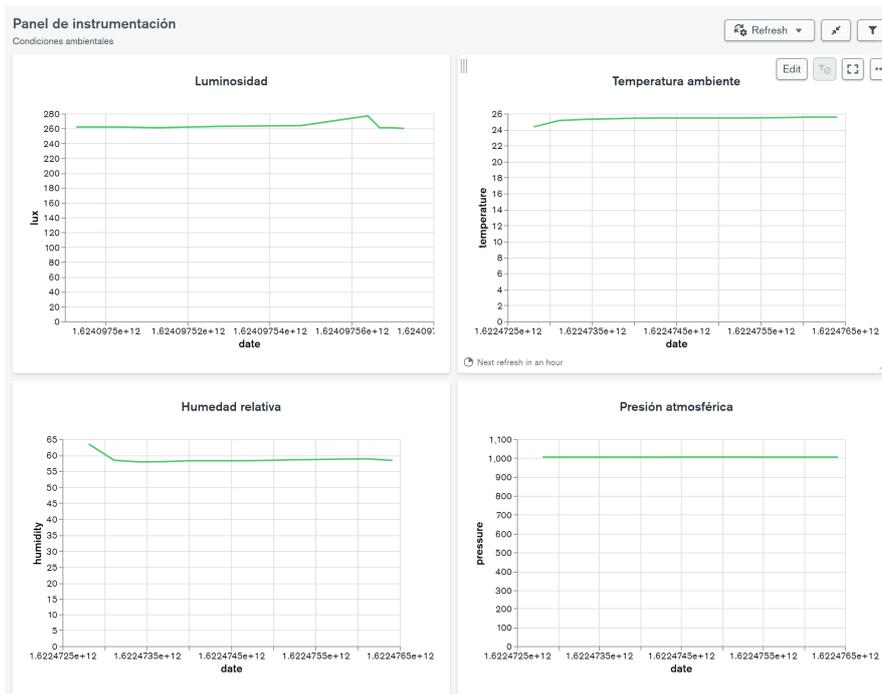


Figura 5.3: Captura de pantalla de un panel de instrumentación generado con las herramientas de *MongoDB* para mostrar los valores de las variables medidas con el dispositivo de adquisición de las condiciones de entorno durante la realización de una sesión de prueba.

que utiliza el sistema, de modo que la información recolectada de un usuario no se mezcla con la de otro. Finalmente, las bases de datos se almacenan dentro de un clúster, el cual posee otros clúster copia del primario para respaldo de la información, para realizar copias de seguridad, actualizaciones o migraciones de datos, etc. En la Figura 5.2 se muestra un mapa conceptual de la arquitectura de almacenamiento descrita.

5.2.2 Acceso a la información y generación de gráficos en tiempo real

Una de las características más destacables de almacenar la información en una base de datos remota es la posibilidad de acceder a los datos desde cualquier parte. Este aspecto es importante porque permite, por ejemplo, entregar los dispositivos de monitorización a diferentes usuarios y tener acceso a la información recolectada por todos en cualquier momento, sin la necesidad de tener que recuperar los equipos para realizar un volcado de memoria. El sistema de almacenamiento utilizado, *MongoDB*, dispone de múltiples

drivers para acceder a la información con los lenguajes de programación más utilizados, algo que facilita en gran medida el desarrollo de aplicaciones. Además, también permite acceder a la información a través de un software propio de gestión con una interfaz gráfica, lo que beneficia a aquellas personas menos expertas en el uso de bases de datos.

Otra de las herramientas que proporciona la plataforma de almacenamiento es la fácil construcción de paneles de instrumentación o *dashboard* para mostrar información con los datos almacenados en las bases de datos. Permite graficar en tiempo real los datos de las variables, realizar cálculos previos a la gráfica o elegir entre diferentes tipo de gráfico. En la Figura 5.3 se puede observar una captura de pantalla con un ejemplo de un *dashboard* generado con las variables de las condiciones de entorno tomadas durante una sesión de pruebas. La herramienta permite editar cada uno de los gráficos por separado, cambiar su tamaño y también elegir entre diferentes períodos de actualización de los datos mostrados. Estas gráficas además pueden compartirse para integrarlas dentro de aplicaciones web o móviles.

5.3 CONCLUSIONES DEL CAPÍTULO

En este capítulo se ha presentado el último de los dispositivos que forma parte del sistema de monitorización de la plataforma. Se trata de un smartphone *Android* con una aplicación instalada que gestiona los dispositivos de monitorización personal y ambiental, se encarga de subir los datos recolectados por éstos a la base de datos remota, y además muestra información sobre los dispositivos y sobre la medida de las variables al usuario o a la persona encargada de sus cuidados. Esta aplicación tiene también integrado el servicio para realizar el análisis del espectro de sonido.

Por otro lado, se expone como se organiza la información recolectada por los sensores, cómo ésta se almacena en la base de datos remota y cuáles son las principales características del sistema de almacenamiento utilizado en la plataforma.

Por último, se han mostrado algunas herramientas que proporciona el sistema de almacenamiento, como por ejemplo la generación de gráficos con los datos almacenados en tiempo real.

INGENIERÍA DE ATRIBUTOS Y GENERACIÓN DE MODELOS PREDICTIVOS

Este capítulo se divide en dos partes principales. Por un lado, se introduce la ingeniería de atributos, donde se expone el procesado de las señales y la generación de atributos adecuados a partir de éstas para formar el dataset utilizado en el entrenamiento de modelos predictivos. La segunda parte presenta una clasificación de diferentes algoritmos de AA, así como los parámetros principales que definen el entrenamiento de los modelos y las métricas empleadas para evaluar el comportamiento de los modelos predictivos generados. "Por último, se muestran diferentes opciones para la generación de estos modelos predictivos mediante el uso de librerías".

6.1 INGENIERÍA DE ATRIBUTOS

El análisis de datos, inteligencia de datos o *Big data*, se encuentra actualmente en gran crecimiento dada la cantidad de información que se genera con el uso de los dispositivos inteligentes, la llegada de la industria 4.0, el vehículo conectado, etc. Todos esos datos recopilados por empresas, fundaciones o gobiernos, proporcionan una información muy valiosa desde un punto de vista económico y social. Pero el análisis de la información supone un trabajo arduo por parte de las personas que se encargan de esta labor. Se trata de uno de los aspectos más importantes para la generación de modelos predictivos. Si los atributos utilizados durante el entrenamiento no son los adecuados, los algoritmos de AA no serán capaces de separar correctamente los valores en el espacio creando modelos que tomen malas decisiones ante nuevas solicitudes de predicción. Es decir, el resultado del entrenamiento serán modelos deficientes o incluso inútiles para la aplicación deseada.

La ingeniería de atributos es el proceso de extracción y creación de atributos que mejoran el modelo de AA a partir de la información bruta recolectada, utilizando técnicas de minería de datos (Khurana et al., 2016). Los atributos se crean a partir de los datos adquiridos previamente con el sistema de adquisición, y estas entradas se

transforman y se preparan para el modelo de AA. También se crean atributos sintéticos que no existen originalmente en el conjunto de datos a partir de la información disponible, por ejemplo mediante la combinación de otros atributos disponibles, y que permiten un mejor rendimiento del modelo. A partir de todos esos atributos se genera el conjunto de datos con el que se entrenará el modelo predictivo.

En esta sección se presentan algunas características que deben cumplir los atributos utilizados, se muestran los procesamientos empleados para la extracción de atributos a partir de las señales obtenidas por los dispositivos de monitorización y se expone el proceso seguido para la generación de dataset de información mediante el cual entrenar los modelos predictivos.

6.1.1 *Procesado de las señales y creación de atributos*

Los atributos deben cumplir con una serie de propiedades para poder ser utilizados en el entrenamiento del modelo. El atributo debe mantener una relación con el objetivo de la aplicación, es decir, debe ser relevante en la salida que busca nuestro modelo. Si no aporta información al resultado únicamente aumentará el tamaño del modelo y prolongará el entrenamiento de éste. Por otro lado, debe existir la certeza de que será posible conocer el valor de ese atributo en el momento de la predicción, de lo contrario el modelo no funcionará correctamente si no dispone de toda la información cuando se realice la inferencia. Otra característica de los atributos es que su valor debe ser numérico y representar una magnitud. Esto es debido a que por ejemplo, una red neuronal no es más que una máquina que realiza operaciones aritméticas, trigonométricas y algebraicas sobre las variables de entrada (S.-C. Wang, 2003). Por lo tanto, aquellos atributos que no sean numéricos pero aporten información relevante al modelo tendrán que ser convertidos o codificados de algún modo antes de introducirlos en el modelo. Por último, también será necesario disponer de suficientes ejemplos de valores del atributo que permitan entrenar el modelo correctamente.

Las reglas anteriores se utilizan para extraer los atributos adecuados para la aplicación y generar un conjunto de datos o *dataset* que se utilizará para entrenar y validar el modelo. Las transformaciones que se realicen sobre las señales disponibles para extraer los atributos dependerán del objetivo final de la aplicación. Por tanto, una vez definido el problema al que se va a hacer frente, se deben analizar las señales y seleccionar aquellas que serán útiles para el modelo. Posteriormente, se realizarán las modificaciones

necesarias. El objetivo final de esta etapa es generar un *dataset* adecuado para entrenar el modelo. Además y como se ha mencionado anteriormente, esta etapa dependerá totalmente de la información obtenida y del resultado que se desea obtener con el modelo. Por lo tanto, está directamente relacionada con el resultado del entrenamiento del modelo y será necesario realizar modificaciones de manera cíclica hasta alcanzar un resultado del entrenamiento que se ajuste a las necesidades de la aplicación. En la mayoría de las ocasiones será necesario modificar el *dataset* con nueva información, cambiar los atributos existentes o eliminarlos.

El primer paso para obtener unos atributos adecuados es realizar un procesado apropiado a las señales obtenidas con los dispositivos de monitorización, para posteriormente aplicar técnicas de minería de datos a las señales obtenidas y generar los atributos. Como se menciona previamente, las tareas desarrolladas en esta etapa dependerán tanto de las señales disponibles como del objetivo de la aplicación a desarrollar. Por tanto, el procesado que se realice a cada una de las señales obtenidas también variará en función de ésta y de la información que aporte. A continuación se presentan las transformaciones aplicadas a cada una de las variables medidas por la plataforma.

- La **temperatura corporal**, la **frecuencia cardíaca**, la **temperatura ambiente**, la **humedad relativa**, la **presión atmosférica**, la **luminosidad** y el **flujo óptico** no requieren de ninguna transformación especial, más allá de los pre-procesamientos aplicados en los respectivos dispositivos de monitorización tras la medición y antes de almacenarse la información en la base de datos.
- **Actividad motora:** De las 9 señales proporcionadas por el sensor (giroscopio, acelerómetro y magnetómetro), únicamente se utilizan los 6 correspondientes al giroscopio (ejes x;y;z) y al acelerómetro (ejes x;y;z), dado que los valores proporcionados por el magnetómetro únicamente aportan información acerca de la dirección de la fuerza. Las señales de cada eje del giroscopio y del acelerómetro son procesadas para eliminar el *baseline* de cada una. Y posteriormente se elimina el pequeño rizado de las señales en torno al cero. Para ello, se define la señal a trozos ($s(t)$) como se presenta en la ecuación 6.1, en la que se fija un límite mínimo positivo (th_P) y un límite máximo negativo (th_N). Los valores de la señal que queden dentro de estos límites se igualarán a cero, el resto mantendrán su valor de medida. Esto se aplica para cada uno de los ejes tanto del giroscopio como del acelerómetro.

$$s(t) = \begin{cases} 0 & \text{si } -th_N \leq s(t) \leq th_P \\ s(t) & \text{si } s(t) < -th_N \text{ ó } th_P < s(t) \end{cases} \quad (6.1)$$

A partir de las señales pre-procesadas de cada eje, se calcula la norma euclidiana o norma vectorial de la señal del giroscopio y de la señal del acelerómetro mediante la Ecuación 6.2 y la Ecuación 6.3 respectivamente.

$$g = \sqrt{g_x^2 + g_y^2 + g_z^2} \quad (6.2)$$

$$a = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (6.3)$$

- **Sonido (frecuencia dominante y sonoridad):** El análisis del espectro de audio se encuentra dividido en 8 bandas de frecuencia, con el valor de sonoridad calculado para cada banda (dB-A). Esto posibilita conocer cuál de las bandas de frecuencia es la dominante en cada instante. Además, permite calcular el valor de energía acumulada en todo el espectro a partir del valor de cada una de las bandas de frecuencia.

En primer lugar, para utilizar la banda de frecuencia dominante como una entrada al modelo predictivo, se debe realizar una codificación que indique de manera numérica la información, dado que se trata de una variable de tipo categórico. Para ello, se ha optado por utilizar una codificación de tipo *one-hot*. Cada uno de los posibles valores de banda se asocia a un índice de entero positivo. Después se genera un vector de longitud igual al número de valores únicos del atributo, en el caso acontecido 8 (1 por banda de frecuencias). Para cada entrada en el modelo, todos los bits del vector tendrán un valor de 0, a excepción del bit correspondiente a la posición que representa el índice de la banda dominante, el cual se fijará a 1. En la Tabla 6.1 se muestra la codificación empleada para el atributo de banda dominante, cuyo resultado de aplicarlo será el mostrado en la Ecuación 6.4.

$$B = \{B_1, B_2, B_3, B_4, B_5, B_6, B_7, B_8\} \quad (6.4)$$

Por otro lado, para obtener el valor de la energía total acumulada, es decir, la sonoridad (en dB-A), se emplea la Ecuación 6.5, donde n es el número de bandas

Valor atributo	Índice	Valor codificado
B_1	0	00000001
B_2	1	00000010
B_3	2	00000100
B_4	3	00001000
B_5	4	00010000
B_6	5	00100000
B_7	6	01000000
B_8	7	10000000

Tabla 6.1: Codificación *one-hot* para la frecuencia dominante en el análisis del espectro de sonido.

en las que se ha dividido el espectro (8) y $sound_i$ es el valor de energía de cada una de las bandas en dB-A.

$$Sonido_{total} = 10 \log \left(\sum_{i=1}^n 10 \frac{Sonido_i}{10} \right) \quad (6.5)$$

- **Cantidad de personas:** El número de personas presentes en el entorno del usuario en cada instante se puede considerar también como una variable de tipo categórica, ya que el valor de la variable no representa una magnitud de cambio en la salida del modelo. Por tanto, se le aplica también una codificación de tipo *one-hot* cuyo resumen se muestra en la Tabla 6.2. Para 10 personas o más en la estancia se reserva el bit de mayor peso. El resultado de aplicarlo antes de introducirlo al modelo se encuentra en la Ecuación 6.6.

$$P = \{P_1, P_2, P_3, P_4, P_5, P_6, P_7, P_8, P_9, P_{10+}\} \quad (6.6)$$

Una vez procesadas las señales de todas las variables de la plataforma, es el turno de la elección de los atributos que formarán parte del conjunto de datos o dataset para el entrenamiento del modelo. En ocasiones, utilizar atributos derivados de los originales puede favorecer el rendimiento del modelo. Por ello, se han calculado una serie de parámetros a partir de los atributos anteriormente presentados, a excepción de aquellos que han sido codificados. Los parámetros generados, en su mayoría parámetros estadísticos, son: *Media*, *Mediana*, *Desviación Estándar*, *Desviación Media Absoluta*, *Percentil*

Valor atributo	Índice	Valor codificado
P_1	0	0000000001
P_2	1	0000000010
P_3	2	0000000100
P_4	3	0000001000
P_5	4	0000010000
P_6	5	0000100000
P_7	6	0001000000
P_8	7	0010000000
P_9	8	0100000000
P_{10+}	9	1000000000

Tabla 6.2: Codificación *one-hot* para la cantidad de personas en el entorno del usuario.

25, Percentil 75, Rango Intercuartil, Asimetría, Curtosis, Moda, Media Truncada, Media Geométrica, Media Armónica, Varianza, Primera derivada en el tiempo, Segunda derivada en el tiempo y la Frecuencia dominante y la Energía acumulada de la respuesta en frecuencia (ésta última definida como la Ecuación 6.7). El uso de parámetros estadísticos como atributos cuando se trabaja con señales continuas como señales fisiológicas o las empleadas en la plataforma aportan información muy valiosa al modelo y permiten que éste aprenda tendencias del usuario así como ayudar a deducir la estructura subyacente del conjunto de datos. El número de muestras utilizado para el cálculo de estos parámetros en cada una de las variables se ha ajustado según su período de muestreo, de manera que no se pierda información. Finalmente, los atributos se normalizan de modo que la media del conjunto sea 0 y la desviación estándar sea 1 aplicando la Ecuación 6.8.

$$Energy = \sum_{i=1}^n FFT(signal_i) * conj(FFT(signal_i)) \quad (6.7)$$

donde FFT es la Transformada Rápida de Fourier (Heckbert, 1995), $conj$ es el conjugado de un número complejo y $signal_i$ es el vector de valores de la ventana i .

$$z = \frac{(x - \bar{X})}{\sigma} \quad (6.8)$$

donde \bar{X} es la media y σ es la desviación estándar del vector de valores, y x es cada una de las entradas del vector de valores.

6.1.2 Generación del dataset para el entrenamiento del modelo

Una vez se han llevado a cabo las diferentes transformaciones y han sido establecidos los atributos que formarán el dataset que será utilizado para generar el modelo predictivo, es el momento de generar éste. Para ello, existen diferentes posibilidades que permiten ajustar cronológicamente los diferentes atributos generados para crear cada una de las entradas que formarán el conjunto de datos.

Tras la etapa previa, se dispone de un total de 182 atributos disponibles generados a partir de las señales capturadas por los dispositivos de monitorización. De éstos, se utilizarán aquellos que sean considerados de interés para la aplicación a desarrollar y tenga sentido su uso. Por ejemplo, para modelos generados en un entorno con la climatología de la estancia controlada y constante no existe interés en el uso de los atributos derivados del sistema de adquisición de condiciones ambientales. Por lo tanto, el número final de atributos será diferente según el modelo que se busque desarrollar. A partir de los atributos seleccionados para la aplicación, se compone el dataset siguiendo el siguiente proceso.

En primer lugar, los atributos de cada una de las variables se encuentran organizados es matrices de vectores ordenados cronológicamente ($\{v1, v2, v3, \dots, vN\}$). Cada matriz contiene un vector diferente para cada uno de los atributos vinculados a la variable y un vector extra con la marca temporal de la entrada. Además, se genera un índice para cada una de las variables a excepción de aquella con la frecuencia de muestro mayor, es decir, la que tiene un tamaño mayor en la matriz vinculada ($\{i_v1, i_v2, i_v3, \dots, i_vN\}$). El índice será el encargado de apuntar a la última entrada de datos de la matriz de atributos, vinculada a dicha variable, introducida en el conjunto de datos según se vaya completando éste.

A continuación, se completa la primera entrada del dataset con las primeras entradas de cada uno de los atributos de todas las variables, sin incluir las marcas temporales. Los valores se introducen separados en columnas, una para cada atributo. Para completar el resto de entradas, se recorre la matriz de la variable con mayor frecuencia de muestreo a partir de la segunda entrada. Entonces, cada nueva entrada del dataset vendrá formada por los valores de los diferentes atributos de dicha variable, junto con los valores de

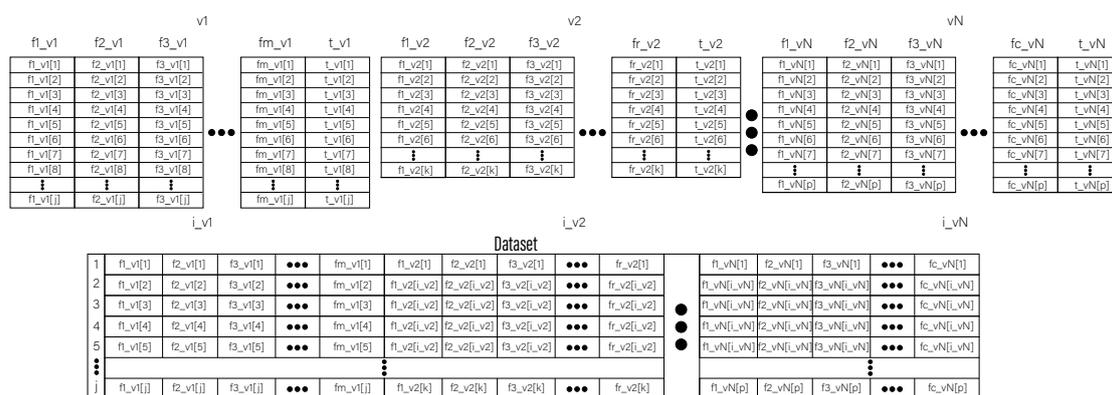


Figura 6.1: Esquema dataset.

los atributos del resto de variables de la posición a la cual esté apuntando al índice correspondiente de cada variable.

Para actualizar dichos índices se realiza una comprobación previa a la generación de una nueva entrada en el dataset donde se revisa si la marca temporal correspondiente a la posición a la que apunta el índice tiene un valor previo en el tiempo a la marca temporal de la posición de la matriz recorrida, es decir, vinculada a la variable con mayor frecuencia. Si el valor temporal es previo, se incrementa en uno el valor del índice correspondiente. De ese modo, cada una de las entradas del dataset estará formada por el valor de los diferentes atributos de una manera coincidente en el tiempo.

Después de haber navegado por toda la matriz, el conjunto de datos se habrá completado con toda la información. Para describir gráficamente este proceso, se muestra un esquema del procedimiento presentado en la Figura 6.1.

6.2 ENTRENAMIENTO Y GENERACIÓN DE MODELOS PREDICTIVOS

Una vez se dispone del conjunto de datos con los atributos generados a partir de la información recolectada por los dispositivos de monitorización, es el momento de entrenar un modelo predictivo que sea capaz de predecir la información deseada a partir de los atributos generados. Para ello, se utilizarán los algoritmos de AA que sean adecuados para el tipo de modelo buscado. El proceso de entrenamiento y evaluación del modelo se realiza de manera cíclica hasta llegar a un modelo con un comportamiento óptimo y suficientemente preciso para la aplicación buscada. Por lo tanto, durante esta etapa tanto el dataset como el algoritmo utilizado para el entrenamiento se modificará

empleando la información obtenida durante el propio entrenamiento y de ese modo mejorar el comportamiento del modelo generado.

Por todo ello, esta sección se organiza en dos partes. Por un lado, se presentan los principales algoritmos de AA. Por otro lado, se muestra el procedimiento seguido para el entrenamiento de los modelos predictivos.

6.2.1 *Aprendizaje automatizado*

Dentro del campo del AA los algoritmos se agrupan en dos ramas principales, el aprendizaje supervisado y el aprendizaje no supervisado. En cada uno de estos grandes grupos se pueden encontrar multitud de algoritmos que serán apropiados para ejecutar diferentes funciones y modelos con una aplicación diferente. Por tanto, es importante conocer la actuación que implementa cada uno de ellos para poder aplicar los algoritmos correctos en función de las necesidades del modelo predictivo que se desea generar.

6.2.1.1 *Aprendizaje supervisado*

En el aprendizaje supervisado los algoritmos tienen acceso a las etiquetas durante el entrenamiento, o lo que es lo mismo, el modelo se entrena a partir de información conocida que ha sido previamente etiquetada. De esa manera, el modelo aprende a partir de situaciones donde ante el valor de los atributos de entrada al modelo, la salida correcta que éstos generan es conocida.

Otra de las ventajas del aprendizaje supervisado es la posibilidad de medir el comportamiento del modelo con información contrastada al disponer de las etiquetas con la salida correcta. Esto permite al algoritmo mejorar el comportamiento del modelo al disponer del error en las predicciones durante el entrenamiento y la validación. Sin embargo, el proceso de etiquetado puede resultar no ser una tarea sencilla en conjuntos de datos muy grandes o complejos. A continuación, se presenta una breve introducción a los diferentes algoritmos utilizados en el aprendizaje supervisado.

- **Métodos lineales**

Se trata de los algoritmos de aprendizaje supervisado más básicos. Se ajusta una relación lineal simple entre los atributos de entrada y la variable de salida que se desea predecir.

- *Regresión lineal*. Se trata de un método para aplicaciones de regresión. Este algoritmo utiliza una relación lineal entre los atributos de entrada (X) y la variable de salida (Y). Si existe una relación lineal entre las entradas y la salida, y además no existe colinealidad (correlación grande entre los atributos de entrada), el funcionamiento de este método puede ser una opción adecuada. Además, al tratarse de un modelo tan sencillo otro aspecto positivo del método es la dificultad para que el modelo se sobreajuste.
- *Regresión logística*. Se trata de un método para aplicaciones de clasificación. Este algoritmo también utiliza una relación lineal, sin embargo, las predicciones de la variable de salida se obtienen aplicando la función logística (Ecuación 6.9), cuyo valor de salida está acotado en el rango entre [0,1]. El resultado de la transformación será la probabilidad de clase, es decir, la probabilidad de que la entrada pertenezca a cada una de las diferentes posibles clases de salida. El resultado de la predicción será asignar a la entrada la clase cuya probabilidad tras aplicar la transformación es mayor. Si las clases que se tratan de predecir no se solapan y se pueden separar linealmente, el algoritmo funcionará correctamente.

$$S(z) = \frac{1}{1 + e^{-z}} \quad (6.9)$$

■ Métodos basados en vecinos

Se trata de algoritmos de aprendizaje que aprenden a identificar las nuevas entradas basándose únicamente en la proximidad con los valores conocidos anteriormente. Estos modelos predicen la salida de las nuevas entradas midiendo la distancia de los nuevos valores respecto de los valores ya existentes.

- *K-Nearest Neighbors (KNN)*. Se trata de un método para aplicaciones de clasificación. Es uno de los algoritmos de clasificación más sencillos. Para identificar un nuevo punto, busca un número k de valores previamente identificados y aplica un método para que esos k valores decidan sobre la identidad del nuevo valor. Por defecto, suele utilizarse como método de decisión la distancia euclídea respecto de los puntos cercanos. Por lo tanto, la elección del valor de k es muy importante. Si éste se establece demasiado pequeño, el modelo será muy flexible y se sobreajustará a los puntos ya conocidos. Sin embargo, si el valor de k es excesivamente alto, el modelo trazará una frontera demasiado rígida entre las clases y se infraajustarán

los datos. Este método tiene la ventaja de poder aprender relaciones no lineales más complejas. Sin embargo, no funciona bien cuando el número de observaciones y de atributos de entrada es muy grande, ya que se vuelve ineficiente desde un punto de vista computacional.

■ **Métodos basados en árboles**

Consiste en métodos donde se construye un árbol de decisión donde todas las instancias se segmentan o estratifican en regiones, guiadas por las etiquetas conocidas. Una vez se completa la segmentación, cada una de las regiones corresponderá con una clase diferentes (en aplicaciones de clasificación) o un rango de valores (en aplicaciones de regresión).

- *Árbol de decisión simple.* Se trata del algoritmo de árboles de decisión más simple de todos, ya que se emplea un árbol único. El método recorre una sola vez todos los datos de entrenamiento creando las reglas que segmentan esos datos. Posteriormente se utiliza ese árbol y las reglas generadas para realizar predicciones sobre nuevas entradas.
- *Agregación de árboles de decisión.* Este algoritmo trata de mejorar la respuesta del árbol de decisión unitario. Toma múltiples muestras aleatorias del conjunto de datos utilizado para el entrenamiento, creando un árbol de decisión diferente para cada una de las muestras. Para calcular la salida de una nueva entrada al modelo, éste promedia las predicciones de los diferentes árboles generados durante el entrenamiento. De esta manera el algoritmo evita que se produzca un sobreajuste como ocurría en el algoritmo anterior.
- *Random Forests.* Con este método se intenta mejorar todavía más el sobreajuste. Para ello no solo se toma una muestra aleatoria del conjunto de datos de entrada, sino que también se toman combinaciones aleatorias de los atributos de entrada utilizados como predictores en el modelo. En primer lugar, el algoritmo selecciona una muestra aleatoria de datos al igual que en el algoritmo anterior. Sin embargo, cuando se va a segmentar el árbol de decisión y crear las reglas de éste, se utiliza una muestra aleatoria de los predictores. Esta característica permite crear árboles de decisión que están menos relacionados entre sí, disminuyendo el sobreajuste.
- *Boosting.* El último de los algoritmos con árboles de decisión es conocido como *boosting*, y al igual que los dos métodos anteriores está basado en el uso

de múltiples árboles de decisión. La principal diferencia se encuentra en que los diferentes árboles de decisión se construyen de manera secuencial. De ese modo, el algoritmo aprende de los resultados obtenidos en la generación de un árbol y utiliza esa información para mejorar el árbol siguiente. Los árboles tienen una segmentación baja, por lo que el algoritmo aprende más lentamente.

- **Support Vector Machine (SVM)**

Se trata de un método que puede utilizarse tanto para aplicaciones de regresión como de clasificación. Este algoritmo sustituye el uso de los árboles de decisión para separar los datos por hiperplanos en el espacio donde los datos se separan en función de los atributos y de las salidas conocidas. Los modelos de SVM permiten algunas excepciones, por lo que no todos los puntos de un mismo hiperplano deben pertenecer a una misma clase. Sin embargo, la distancia entre los puntos que definen los límites del hiperplano de una clase y los puntos que definen el hiperplano de otra clase deben maximizarse. Otra característica de estos modelos es que los límites de los hiperplanos no tienen que ser lineales, sino que se pueden utilizar kernels no lineales para separar los datos de una forma más flexible.

- **Redes neuronales**

El último de los métodos de aprendizaje supervisado presentados son las redes neuronales. Este tipo de modelos aprenden a representar los datos con una estructura que simula el cerebro humano, donde las neuronas se encuentran conectadas entre sí. Estos modelos se componen de una capa de entrada, una o más capas ocultas y una capa de salida. La capa de entrada se encarga de coger los atributos utilizados en el modelo. Las capas ocultas consisten en una jerarquía anidada donde cada capa intenta comprender cómo se relaciona la capa anterior con la capa de salida. Por último, la capa de salida trata de ajustar la salida del modelo a una variable de salida buscada. Gracias a esa jerarquía anidada, una red neuronal es capaz de aprender conceptos muy complejos, construidos tomando como base otros más sencillos. Este método es uno de los algoritmos más potentes dentro del AA, sin embargo, las redes neuronales son muy propensas a tener sobreajuste y además son difíciles de ajustar correctamente.

6.2.1.2 *Aprendizaje no supervisado*

En el aprendizaje no supervisado no se dispone del valor de las etiquetas de salida del conjunto de datos a diferencia del aprendizaje supervisado. En lugar de tratar de predecir el valor de salida, los algoritmos de aprendizaje no supervisado intentarán aprender la estructura subyacente de los datos. Esto permitirá extraer patrones de los datos, agruparlos en categorías previamente desconocidas o detectar anomalías en la información, por ejemplo. A continuación, se presenta una breve introducción a los diferentes algoritmos utilizados en el aprendizaje no supervisado.

■ **Métodos de reducción de la dimensionalidad**

Se trata de una serie de algoritmos que proyectan los atributos de entrada originales desde la dimensión original de éstos hasta una dimensión reducida, filtrando los atributos no relevantes y manteniendo aquellos más importantes para obtener la salida del modelo. Aplicar una reducción de la dimensionalidad permite a los algoritmos de [AA](#) identificar patrones de una manera más eficaz, así como mejorar el comportamiento de problemas a gran escala que son muy costosos desde un punto de vista computacional.

• *Proyección lineal*

Estos algoritmos se basan en la proyección lineal de los datos desde el espacio original de alta dimensión a un espacio de menor dimensión.

- *Análisis de componentes principales.* El Análisis de Componentes Principales o [PCA](#), por sus siglas en inglés, busca encontrar una representación de baja dimensión de los datos manteniendo la variación de éstos tanto como sea posible. Se basa en que no todos los atributos son iguales, ya que el valor de ciertos atributos no varían mucho dentro del conjunto de datos, y por lo tanto, estos atributos son menos útiles para explicar el conjunto de datos. Busca convertir el conjunto original de datos donde los atributos están fuertemente correlacionados en otro donde los nuevos atributos no mantengan una correlación lineal. Aplicando este algoritmo el número de dimensiones que queda es considerablemente menos al original aunque se pierde parte de la varianza. Sin embargo, la estructura subyacente de los datos será más fácil de identificar, permitiendo realizar las tareas, por ejemplo de agrupación, de manera más eficiente.

- *Descomposición en valores singulares*. Este algoritmo reduce el rango de la matriz original de atributos a un rango menor, de manera que la matriz original pueda ser reconstruida utilizando una combinación lineal de los vectores de la nueva matriz. Para componer esa nueva matriz de menor rango, el algoritmo mantiene los vectores de la matriz original que poseen más información, es decir, el valor singular más alto. Por lo tanto, la nueva matriz generada recoge los elementos más importantes del espacio de atributos original.
- *Proyección aleatoria*. Este método consiste en proyectar puntos del espacio de altas dimensiones original a un espacio de dimensiones mucho más bajas, de modo que se conserve la escala de distancias entre los puntos. Para ello se puede utilizar una matriz dispersa aleatoria o una matriz gaussiana aleatoria.

- ***Aprendizaje múltiple***

Estos algoritmos realizan una reducción no lineal de la dimensionalidad, es decir, aplican una transformación no lineal del conjunto de datos para reducir la dimensionalidad de éste.

- *Isomap*. Este algoritmo aprende la geometría intrínseca del conjunto de datos realizando una estimación de la distancia geodésica entre cada punto y sus puntos vecinos en lugar de utilizar la distancia euclidiana. Emplea este procedimiento para embeber el espacio original de altas dimensiones en un espacio de dimensiones más bajas.
- *T-Distributed Stochastic Neighbor Embedding (t-SNE)*. Este algoritmo integra los datos del espacio original de altas dimensiones en un espacio de sólo dos o tres dimensiones. Esto permite visualizar los datos transformados de una manera más sencilla, donde las instancias similares se representan cercanas y las que son más diferentes aparecen alejadas.
- *Codificación dispersa*. Este algoritmo aprende una representación dispersa de los datos subyacentes. Esta representación se forma con unos vectores binarios donde cada instancia del conjunto de datos se puede reconstruir como una suma ponderada de los elementos representativos. La matriz generada con los vectores, la cual se conoce como diccionario, está formada por ceros en su mayor parte y unos pocos pesos

diferentes a cero. El algoritmo es capaz de identificar los elementos más representativos del espacio de atributos original, los cuales se corresponden con los pesos más diferentes a cero de la matriz. De manera contraria, los atributos del espacio original menos importantes tendrán un peso cercano a cero en la matriz.

- *Análisis de componentes independientes*

Este método se aplica cuando dentro del conjunto de atributos hay muchas señales independientes mezcladas. Utilizando este algoritmo se pueden separar esas señales en sus diferentes componentes individuales. Si una vez realizada la separación se desean obtener los atributos originales, éstos se pueden reconstruir como combinación de algunos de los componentes individuales generados.

- *Asignación latente de Dirichlet*

El aprendizaje no supervisado intenta también explicar la composición de un conjunto de datos aprendiendo porqué algunos de los elementos de éste son similares entre sí. Este algoritmo aprende elementos no observados dentro del conjunto de datos. Por ejemplo, si se analizase un texto el algoritmo sería capaz de aprender que ciertas palabras a pesar de no estar relacionadas entre sí se agrupan formando una estructura. Esa estructura se puede modelar como un elemento no observado y tras el entrenamiento el modelo será capaz de identificar diferentes estructuras y agruparlos para diferentes temas dentro del texto.

- **Clustering**

Esta es otra de las aplicaciones principales del aprendizaje no supervisado. Se trata de encontrar patrones agrupando instancias de datos similares. Esto puede realizarse con múltiples algoritmos y se utiliza en multitud de aplicaciones del mundo real como la segmentación del mercado, determinar los diferentes patrones climáticos de una región o descubrir las zonas con elevadas tasas de criminalidad, por ejemplo.

- *K-Means*. En este algoritmo se especifica el número de clústeres deseados (k) y el algoritmo asigna cada una de las instancias a uno de esos clústeres. El método optimiza la agrupación de modo que se minimice la variación, conocida como inercia, dentro del clúster. Lo que busca el algoritmo es

conseguir que la suma de las variaciones dentro de cada uno de los clúster sea lo más pequeña posible. En una primera iteración, asigna aleatoriamente cada instancia a unos de los clústeres. A continuación, realiza múltiples iteraciones reasignando las instancias de manera que se minimice la distancia euclidiana entre cada una de las instancias y el punto central de su clúster, conocido como centroide.

- *Clustering jerárquico*. En este algoritmo, al contrario que en el anterior no requiere seleccionar el número de clústeres con anterioridad. Este método construye un dendograma, que podemos interpretar como un árbol invertido donde las hojas se encuentran en la parte inferior y el tronco en la parte superior. Las hojas de la parte inferior representan cada una de las instancias o entradas del conjunto de datos. El algoritmo une esas hojas a medida que se asciende por el dendograma en función de la similitud entre éstas, es decir, las instancias o grupos de instancias más similares se unirán antes y las que no son similares se unirán más arriba en el árbol a medida que se va avanzando. Finalmente todas las entradas se acaban uniendo y se forma el tronco superior del dendograma. Una vez finalizado algoritmo podemos determinar en qué punto del dendograma queremos cortar. La selección de ese punto de corte será lo equivalente a seleccionar el número de k clústeres del método anterior, sin embargo, en esta ocasión se dispone la información antes de elegir el número de clústeres.
- *Density-based Spatial Clustering (DBSCAN)*. En este algoritmo tampoco será necesario especificar el número de clústeres, y está basado en la densidad de puntos. El DBSCAN agrupa las instancias que están más juntas en el espacio siempre que exista un número mínimo de instancias a una determinada distancia. Se debe especificar ese número mínimo de instancias para formar el grupo así como la distancia mínima a la que deben estar. Las instancias que no se encuentren dentro de las distancias mínimas a los diferentes clústeres generados se etiquetarán como valores atípicos.

■ **Métodos de extracción de atributos**

Dentro del aprendizaje no supervisado existen algoritmos específicos para la extracción de atributos dado que éstos permiten obtener nuevas representaciones de los atributos originales. Esto se puede utilizar por ejemplo para generar una mejora en el rendimiento de problemas de aprendizaje supervisado.

- *Autoencoders*. Este algoritmo emplea una red neuronal no recurrente retroalimentada hacia adelante para aprender una representación del conjunto de datos. El número de nodos de la capa de entrada coincide con el número de nodos de la capa de salida. Esta red neuronal se conoce como autoencoder porque reconstruye las entradas originales a partir de una nueva representación que aprende en las capas ocultas. Para ello, cada capa oculta aprende una nueva representación, y las capas siguientes se basan en esa nueva representación para aprender una nueva. Así, cada capa que avanza la red aprende una nueva representación más compleja a partir de una más sencilla. Finalmente la capa de salida es la representación resultado que ha aprendido la red neuronal.
- *Extracción de atributos utilizando entrenamiento supervisado de redes neuronales prealimentadas*. Este método plantea utilizar nuevamente una red neuronal no recurrente retroalimentada hacia adelante donde en cada capa oculta la red aprende una nueva representación de los atributos originales, pero en esta ocasión la capa de salida intentará predecir la etiqueta correcta para cada instancia. De igual modo, en cada capa oculta cuando la red genera una nueva representación se guía exclusivamente por las posibles etiquetas de salida. Finalmente, para extraer la nueva representación aprendida por la red neuronal se coge la información de la penúltima capa, dado que la capa de salida se corresponde con la etiqueta predicha.

■ Métodos de aprendizaje profundo no supervisado

Estos métodos están basados en redes neuronales profundas donde las capas ocultas aprenden representaciones internas para resolver el problema planteado. Esas representaciones mejoran en el tiempo con cada iteración en función de cómo la red neuronal utiliza el gradiente de la función de error en cada una de esas iteraciones durante el entrenamiento para actualizar la matriz de pesos de los nodos. Este tipo de acciones requieren de un alto gasto computacional y además, pueden aparecer problemas de propagación muy lenta si el gradiente de la función de error es muy pequeño o problemas de inestabilidad si éste es demasiado grande.

- *Pre-entrenamiento no supervisado*. Este método se basa en entrenar las redes neuronales en múltiples etapas para evitar los problemas del entrenamiento de redes profundas. De esta manera cada etapa implica el entrenamiento de

una red neuronal poco profunda y la salida de ésta se convierte en la entrada de la siguiente red neuronal. La salida de la primera red, la de entrada, suele ser una red no supervisada, pero las siguientes redes son supervisadas. De ese modo, el preentrenamiento no supervisado de la primera red permite obtener una representación mejorada de los atributos que puede aprovechar la parte supervisada para solventar el problema planteado.

- *Máquinas de Boltzmann restringidas*. Este es un método de pre-entrenamiento no supervisado donde la red neuronal poco profunda está formada por sólo dos capas, la primera es la capa de entrada y la segunda es la capa oculta. Dentro de la red, cada nodo de la capa de entrada está conectado a todos los nodos de la capa oculta pero no están conectados a los nodos de su misma capa.
- *Redes de creencia profunda*. Este método emplea múltiples máquinas de Boltzmann restringidas enlazadas entre sí para formar una red neuronal de múltiples etapas donde la capa oculta de una máquina de Boltzmann restringida se utiliza como la capa de entrada de la siguiente.
- *Redes generativas antagónicas*. Las redes generativas antagónicas o GAN por sus siglas en inglés son muy útiles para crear datos de manera sintética o realizar la detección de anomalías. En este método se utilizan dos redes neuronales, la primera conocida como generador, que crea los datos sintéticos basándose en un modelo de distribución de datos a partir de muestras reales que se introducen. La segunda red neuronal, que se conoce como discriminador, se encarga de diferenciar entre los datos generados y los datos del conjunto real. Estas dos redes compiten entre sí, la primera trata de engañar a la segunda con los datos generados y la segunda trata de identificar como falsos los datos sintéticos. De ese modo, el generador es capaz de aprender la estructura subyacente de los datos y el discriminador de identificar anomalías en el conjunto de datos.

6.2.1.3 *Aprendizaje por refuerzo mediante aprendizaje no supervisado*

Se trata de una tercera rama del [AA](#), donde un agente determina su comportamiento óptimo dentro de un determinado entorno en función de una retroalimentación o recompensa que recibe. Esa retroalimentación se conoce como señal de refuerzo y el objetivo del agente es maximizar su recompensa acumulada a lo largo del tiempo. Este

tipo de aprendizaje se aplica en operaciones bursátiles, videojuegos o juegos de mesa, control de máquinas o coches autónomos, por ejemplo, en la actualidad.

6.2.1.4 *Aprendizaje semisupervisado*

Los algoritmos de *AA* de las ramas principales, supervisado y no supervisado, también pueden mezclarse para encontrar patrones nuevos a partir de datos no etiquetados mientras además se detectan patrones conocidos en datos ya etiquetados. Este tipo de soluciones serán útiles para problemas híbridos donde parte de la información del conjunto de datos es conocida, pero otra parte no se conoce su estructura.

- *Detección de anomalías*

Cuando se aplica un algoritmo para reducir la dimensionalidad del conjunto de datos a un espacio transformado de menores dimensiones hay una parte de los puntos que se concentran en una zona de forma densa, este es el espacio normal. Sin embargo, también aparecen otros puntos que se encuentran más alejados de esa zona densa y se les denomina valores atípicos, o también anomalías. En algunas ocasiones el estudio de esos valores puede ser el fin de la aplicación a desarrollar. Por ejemplo, este tipo de métodos se emplean en la detección de fraudes con tarjetas de crédito, fraudes a las aseguradoras o fallos en el mantenimiento de equipos críticos como son en aviones o trenes, así como para la detección de enfermedades. Por ello, se suele emplear algún algoritmo de clustering que permita agrupar esas anomalías y posteriormente etiquetarlas de manera manual en función del comportamiento que representen. Utilizando un sistema de este tipo, se dispone de un modelo de aprendizaje no supervisado que es capaz de identificar las anomalías, agruparlas de manera apropiada y además, utilizando las etiquetas realizar recomendaciones a las personas que estén al cargo de solucionar esos problemas o atender a la solución correcta. Con este tipo de sistemas de detección se puede coger un problema a priori de aprendizaje no supervisado y transformarlo en uno semisupervisado que con el tiempo permita ejecutar algoritmos de aprendizaje supervisado con las etiquetas que se desprenden del aprendizaje no supervisado previo.

6.2.2 Selección de algoritmo y entrenamiento de un modelo predictivo

La elección de uno o más algoritmos para el entrenamiento de un modelo predictivo no es algo sencillo ni que pueda determinarse con un mecanismo concreto. El uso de los algoritmos de [AA](#) a emplear para un conjunto de datos dependerá de muchos factores como son el tipo de problema al que enfrentarse, la precisión que requiere ese problema, el tiempo para entrenamiento, si se trata de un problema lineal o no, el tamaño del conjunto de datos de entrenamiento, de la cantidad de parámetros buscados en la salida o del número de atributos con el que se vaya a trabajar. Para encontrar la mejor solución, hay que realizar muchos experimentos, evaluar los algoritmos de aprendizaje automático y ajustar sus hiperparámetros.

Para realizar el entrenamiento del modelo es recomendable disponer de gran cantidad de datos que permitan obtener predicciones fiables. No obstante, en ocasiones esa disponibilidad de datos está limitada. Para ese tipo de problemas puede resultar útil la elección de algoritmos con una varianza baja, como son la regresión lineal o los algoritmos de [SVM](#). Sin embargo, si se dispone de un dataset lo suficientemente grande se puede optar por algoritmos con una mayor varianza como los árboles de decisión o el [KNN](#). Otro aspecto importante relacionado con la cantidad de datos es el sobreajuste u "overfitting", es decir, la sobreadaptación del modelo a los datos con los que ha sido entrenado. Esto impide que haga buenas predicciones con nuevas entradas que no se ajusten a los valores con los que se ha entrenado el modelo. Por ello, es importante que además de disponer de una cantidad suficiente de instancias, éstas abarquen un rango amplio donde estén todos los valores factibles.

Por otro lado, la precisión de un modelo mide cómo de acertada es la respuesta del modelo cuando predice un valor para una observación o instancia determinada. Los modelos generados con algoritmos más fácilmente interpretables, es decir, que se puede entender mejor cómo se relacionan los atributos utilizados como predictores con la respuesta, son más restrictivos a la hora de ajustarse a la estructura subyacente de los datos y suelen tener una precisión menor que aquellos más flexibles que ofrecen una mejor precisión a costa de una peor interpretabilidad. En general, a medida que aumenta la flexibilidad del algoritmo (es capaz de adaptarse a estructuras más complejas de los datos), disminuye su interpretabilidad.

Con respecto al tiempo de entrenamiento, si se busca obtener una mayor precisión esto implicará un aumento del tiempo. Si además el conjunto de datos para el entrenamiento es muy grande, este aspecto es fundamental y se debe alcanzar una

solución de compromiso entre ambas, precisión y tiempo. La elección de uso de un algoritmo u otro variará enormemente el tiempo necesario, pues los algoritmos más complejos como son las redes neuronales o los SVM requieren de grandes tiempo para alcanzar la convergencia o ajustar los parámetros.

El uso de algoritmos lineales suele ser más sencillo y rápido pero la mayoría de los conjuntos de datos no suelen seguir tendencias lineales. Una forma fácil de comprobar el nivel de linealidad de los datos es aplicar un algoritmo de regresión lineal a un subconjunto de los datos y comprobar el nivel de los errores residuales del modelo. Si el error es alto significará que el conjunto no se puede ajustar a la linealidad y tendrá que emplearse otros algoritmos más complejos.

Por otra parte, el dataset puede contener un gran número de atributos y no todos ellos tienen porque ser relevantes para el problema en cuestión. El uso de algunos algoritmos con un conjunto de datos donde hayan muchos atributos puede no funcionar correctamente o necesitar de un tiempo de entrenamiento inviable. A pesar de que algunos atributos sean capaces de trabajar con un espacio de altas dimensiones, reducir la dimensionalidad del conjunto o seleccionar los atributos más relevantes para la aplicación utilizando métodos de reducción de la dimensionalidad o de selección de atributos mejorará el resultado del modelo y permitirá utilizar un número mayor de algoritmos en el entrenamiento.

A la hora de enfrentarse a un nuevo problema se debe plantear en primer lugar cuál es el problema y qué objetivo se desea alcanzar. Una vez definido el problema, se deben analizar los datos disponibles y trabajar con ellos porque el resultado del modelo dependerá en gran parte en cómo de buenos son esos datos. A continuación, se comienza aplicando algoritmos sencillos para establecer un modelo de referencia el cual a partir de él se vayan aplicando nuevo algoritmos más complejos y comparando los resultados. Finalmente se seleccionará el algoritmo o algoritmos que mejor resultados proporcionen y se continuará trabajando con ellos para optimizarlos y tratar de llegar a un modelo final que se ajuste a los objetivos planteados.

6.2.2.1 Métricas de evaluación de resultados

Para poder comparar y evaluar los modelos entrenados es necesario establecer unos parámetros que midan el rendimiento predictivo del modelo. Para ello, cada algoritmo debe evaluarse utilizando unas métricas que sean adecuadas para ello.

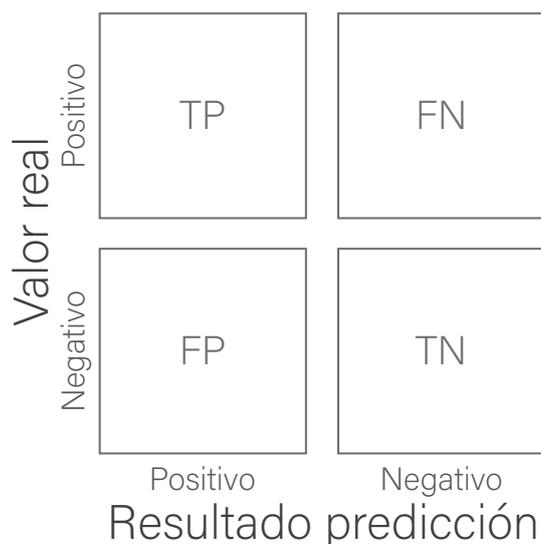


Figura 6.2: Ejemplo de matriz de confusión para un problema binario.

En el caso de los modelos de clasificación, el modelo va a predecir entre diferentes categorías posibles. Para evaluar el comportamiento de estos modelos se utiliza la matriz de confusión, donde se presentan los resultados de predicción frente a los valores reales de cada categoría. En la Figura 6.2 se muestra una matriz de confusión de ejemplo para un problema binario (dos posibles categorías), donde se define una categoría como resultado positivo y la otra como negativo. A partir de este ejemplo se puede observar como se conforma una matriz de confusión. Los verdaderos positivos (TP) es cuando el modelo predice un positivo y se corresponde en la realidad con un valor positivo. Cuando el valor que predice el modelo es positivo y se trata realmente de un valor negativo se conoce como falso positivo (FP). De igual modo cuando el modelo predice un verdadero negativo (TN) éste se corresponde en realidad con un negativo y al predecir un negativo tratándose de un positivo se le llama falso negativo (FN)

A partir de la matriz de confusión se pueden obtener además otras métricas también utilizadas en la evaluación de modelos de clasificación. A continuación se listan las más importantes:

- **Exactitud:** Este parámetro mide el número de instancias que han sido correctamente clasificadas en comparación con el número total de instancias.

$$accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

- **Sensibilidad:** La sensibilidad mide el número de verdaderos positivos que ha predicho el modelo en comparación con el número total de positivos reales del conjunto.

$$recall = \frac{TP}{TP + FN}$$

- **Precisión:** La precisión mide el número de verdaderos positivos predichos por el modelo comparados con el total de positivos predichos, tanto verdaderos como falsos.

$$precision = \frac{TP}{TP + FP}$$

- **Parámetro f1:** Se trata de un parámetro que mide el compromiso entre la precisión y la sensibilidad. Las puntuaciones cercanas a 1 son las deseables.

$$f1score = 2 * \frac{precision * recall}{precision + recall}$$

Para los modelos de regresión se suelen utilizar principalmente tres parámetros para medir el comportamiento: el error medio absoluto, el error cuadrático medio y la raíz cuadrada del error cuadrático medio.

- **Error medio absoluto:** Este parámetro mide el valor promedio de la diferencia en términos absolutos entre el valor que ha predicho el modelo y el valor real.

$$MAE = \frac{1}{n} \sum_{i=1}^n |real_i - predict_i|$$

- **Error cuadrático medio:** El error cuadrático medio mide el valor promedio de la diferencia entre el valor predicho por el modelo y el valor real al cuadrado de todas las instancias del conjunto.

$$MSE = \frac{1}{n} \sum_{i=1}^n (real_i - predict_i)^2$$

- **Raíz del error cuadrático medio:** Se utiliza la raíz del error cuadrático medio (Root Mean Square Error (**RMSE**), en inglés) porque es más fácil de interpretar.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (real_i - predict_i)^2}$$

6.2.2.2 Hiperparámetros del entrenamiento

Los hiperparámetros son propiedades que se establecen antes del entrenamiento, como por ejemplo, elegir el número de clústeres k para el algoritmo de **KNN** o la tasa de aprendizaje en una red neuronal. Hay que distinguir estos hiperparámetros de los parámetros del algoritmo, que son las propiedades que éste aprende durante el entrenamiento del modelo.

La optimización de los hiperparámetros es el proceso de encontrar los mejores valores posibles con el fin de mejorar el rendimiento, ya sea obtener una mayor precisión en modelos de clasificación o un menor **RMSE** en modelos de regresión. Para ello se entrena un modelo con diferentes combinaciones de valores de los distintos hiperparámetros y se evalúan los modelos para hallar la mejor solución. Existen cuatro técnicas principales para obtener la mejor combinación de hiperparámetros:

- **Búsqueda en rejilla:** En este método se especifican combinaciones de valores para cada hiperparámetro y se evalúan todas. Si por ejemplo el algoritmo tiene 3 hiperparámetros diferentes y para cada uno de ellos se establecen 5 valores posibles esto resultará en 15 combinaciones posibles y se probará con todas ellas. La combinación que arroje el mejor resultado será la que se emplee en el modelo final.
- **Búsqueda aleatoria:** En este método se especifican rangos u opciones para los diferentes hiperparámetros y aleatoriamente dentro de esos rangos se seleccionan diferentes combinaciones. El número de combinaciones que se evaluarán lo debe indicar el usuario. Esto permite reducir el tiempo de computación con respecto al método anterior.
- **De grueso a fino:** Se trata de una técnica que se puede aplicar tanto para la búsqueda en rejilla como para la búsqueda aleatoria. Consiste en explorar un rango amplio de valores en los hiperparámetros y analizar los resultados para intentar extraer un patrón o una zona de valores donde parece que el comportamiento del modelo mejore. Después, se debe repetir el proceso pero ajustando cada vez más el rango de valores a un intervalo más reducido. También se puede mantener constante un hiperparámetro sobre un valor optimizado y continuar ajustando el resto hasta obtener la mejor combinación posible.
- **Optimización bayesiana:** Este método utiliza el enfoque de ser un propio modelo de **AA** construyendo un modelo donde los hiperparámetros son los nuevos

atributos y el rendimiento del modelo es la variable objetivo. Tras cada iteración con una combinación de valores de hiperparámetros se añade un nuevo punto y se construye un nuevo modelo. Esta técnica permite encontrar más hiperparámetros optimizados, sin embargo, el coste computacional es muy alto.

6.2.2.3 *Acondicionamiento del dataset*

Una vez disponemos del dataset, generado en el apartado 6.1.2, lo primero que se realiza antes de empezar con el entrenamiento es la división de éste en tres partes diferentes. En la Figura 6.3 se muestra un diagrama con esta división. El conjunto inicial es el dataset generado, y a partir de éste se realiza una primera división donde se obtiene por un lado el subconjunto de datos para el entrenamiento, que incluye la gran mayoría de los datos del conjunto global. Este conjunto de entrenamiento es el que utiliza el modelo para aprender a procesar la información. A partir de estos datos, el algoritmo ajusta los parámetros del clasificador o del modelo de regresión. Se puede utilizar este conjunto para entrenar modelos con diferentes algoritmos y posteriormente comparar los resultados. Por otro lado, se obtiene un subconjunto de datos con una pequeña parte del conjunto inicial que se utilizará para evaluar el modelo una vez finalizado el entrenamiento de éste. Una distribución de datos estándar que se suele utilizar para realizar la división es de un 70 % de los datos para el subconjunto de entrenamiento y el 30 % restante para el subconjunto de evaluación. Previamente a la división, las diferentes entradas del dataset se mezclan de manera aleatoria. De ese modo habrá una distribución heterogénea de los datos y se evita que se agrupen instancias similares en ambos subconjuntos de datos, hecho que disminuiría la varianza de los subconjuntos y podría derivar en un sobreajuste del modelo.

Durante el entrenamiento se realiza una segunda división, en este caso sobre el subconjunto de datos para entrenamiento. Esta división se aplica para obtener dos subconjuntos del subconjunto, uno principal que se utiliza para entrenar el modelo y uno secundario que se utiliza para validar el modelo entre iteraciones del entrenamiento. Existen diferentes métodos para realizar esta división para validación, el método más utilizado es la validación cruzada (Browne, 2000). Se trata de un método estadístico que consiste en dividir los datos en dos subconjuntos como se menciona anteriormente, uno para entrenar el modelo y otro para validarlo (Refaeilzadeh et al., 2016). La modalidad más utilizada para aplicar este método es la validación cruzada "k-fold", donde el subconjunto de datos de entrenamiento se divide en k segmentos de igual o similar tamaño y se realizan k iteraciones de entrenamiento y validación, de manera que en

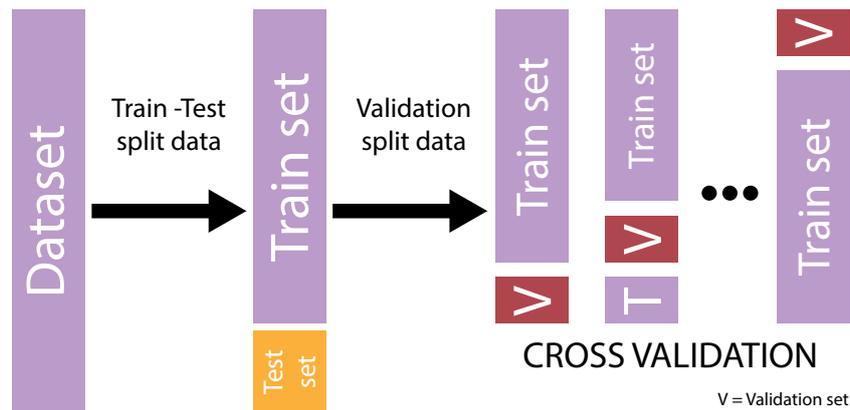


Figura 6.3: Diagrama de la división del conjunto de datos y del proceso de validación cruzada.

cada iteración el segmento utilizado para validar el modelo sea uno diferente, y el resto de segmentos ($k - 1$) se usan para el entrenamiento del modelo en esa iteración.

6.3 CONCLUSIONES DEL CAPÍTULO

En este capítulo se ha presentado el proceso para extraer los atributos que se utilizarán para el entrenamiento de modelos predictivos, a partir de las variables medidas por los dispositivos de monitorización. Se han procesado las señales que lo requerían y se han codificado aquellas que era necesario antes de poder introducirlos en algoritmos de AA. Con todos los atributos generados se conforma el dataset general mediante un método también presentado en este capítulo.

Por otro lado, se presentan brevemente los diferentes algoritmos de AA clasificados en dos grupos principales como son el de aprendizaje supervisado y aprendizaje no supervisado. En línea con esta clasificación y los diferentes métodos se presentan también las métricas a utilizar para evaluar y comparar los modelos generados así como diferentes técnicas para optimizar los hiperparámetros del entrenamiento.

Finalmente, se expone el procedimiento para separar el conjunto de datos en diferentes subconjuntos para las diferentes partes del proceso, donde se obtiene un subconjunto para el entrenamiento y otro para la evaluación del modelo, así como la técnica de validación cruzada realizada durante el proceso de entrenamiento.

EXPERIMENTACIÓN EN ENTORNO CLÍNICO CON USUARIOS CON TRASTORNO DEL ESPECTRO DE AUTISMO

En este capítulo se presenta el trabajo desarrollado para llevar a cabo una experimentación con personas con TEA dentro de un entorno clínico utilizando la plataforma de dispositivos desarrollada en esta tesis. En la primera parte del capítulo se muestra la configuración del entorno donde se desarrolla la experimentación y implantación de los sistemas de adquisición en él. Además, se presenta el protocolo seguido durante las sesiones con los usuarios participantes. En la segunda parte se muestran los resultados alcanzados durante la experimentación y se analizan los registros obtenidos para extraer información utilizando métodos de AA. Finalmente, se presenta una aplicación para compartir los resultados de una manera dinámica.

7.1 IMPLANTACIÓN DE LA PLATAFORMA DESARROLLADA EN UN ENTORNO CLÍNICO

Los dispositivos de monitorización presentados en esta tesis han sido desarrollados pensando en su uso para el día a día de las personas que lo requieren. Sin embargo, para conseguir la máxima utilidad en la plataforma es necesario conocer al usuario que la va a utilizar y adaptar el sistema a éste. Uno de los objetivos futuros que se desea alcanzar con este trabajo es el de implementar un cliente remoto que sea capaz de analizar en tiempo real la situación del usuario y del entorno que le rodea, y mediante uno o más modelos predictivos personalizados al usuario sea capaz de predecir los cambios en el usuario debidos al entorno. Para llegar a desarrollar ese tipo de modelos es necesario tener una enorme cantidad de información sobre el usuario llevando a cabo todo tipo de tareas y en todo tipo de situaciones, dado que el estado físico y el comportamiento de una persona depende de multitud de factores. Por lo tanto, implementar el sistema para un uso diario inmediatamente no es viable y será necesario seguir un proceso con diferentes etapas que permita ir integrando información del usuario en los modelos poco a poco.

Un punto de partida para comenzar a obtener información de los usuarios puede ser en un entorno controlado donde estos acudan de manera periódica y se puedan planificar las tareas que llevan a cabo. Muchas personas con TEA, sobretodo en la niñez, requieren de sesiones de trabajo con profesionales especializados que les ayuden a controlar los problemas derivados de su patología, por ejemplo la agresividad, las fobias a objetos o tareas como la higiene o problemas de hiperactividad, entre otros muchos. Los profesionales que les atienden disponen de un entorno donde consiguen que estas personas se sientan cómodas y puedan trabajar con ellos. Además, preparan tareas que se ajustan al nivel de desarrollo de la persona y siempre buscando una evolución en el problema a tratar. Por lo tanto, una base para comenzar a trabajar con los dispositivos de la plataforma en personas con TEA puede ser aprovechar estos entornos controlados con personal cualificado para iniciar el proceso de registro de señales con usuarios.

La experimentación expuesta en este capítulo se ha llevado a cabo en colaboración con la Clínica Universitaria (UMH, 2021). Se trata de un centro de investigación aplicada y transferencia asistencial de la Universidad Miguel Hernández de Elche, en el cual disponen de una unidad especializada en TEA donde ofrecen asesoramiento, evaluación y tratamiento en grupo e individualizado para niños que sufren de esta patología.

Para la realización de las pruebas, los especialistas de la clínica han sido los encargados de escoger a los usuarios participantes. Los tutores legales de cada uno de los usuarios han dado su aprobación para participar en el estudio, y para ello han firmado un consentimiento informado donde se les explica el estudio y se les informa que pueden abandonar el mismo en cualquier momento si así lo desean. Además, dan su consentimiento explícito a los investigadores para utilizar los datos fisiológicos adquiridos durante las pruebas con fines de investigación. Por su parte los investigadores tratarán esos datos siempre de forma anónima y durante la experimentación se respetarán los Principios Éticos para la Investigación Médica en Seres Humanos de la Declaración de Helsinki (Association, 2013).

La duración de las pruebas no tiene un período determinado, por lo que no existe un número máximo de sesiones establecido. De igual manera, las tareas a desarrollar durante las sesiones no son predefinidas, los especialistas serán los encargados de planificar cada una de ellas según el usuario y su progresión. La adquisición de nuevos registros se prorrogará en el tiempo mientras todas las partes involucradas sigan de acuerdo en ello. Se podrá variar la experimentación o integrar nuevas situaciones según

la evolución del usuario y los resultados obtenidos si así lo autorizan los especialistas de la clínica y los tutores legales del usuario.

7.1.1 *Configuración del entorno clínico*

Para la realización de la experimentación se ha habilitado una de las salas de la clínica donde los profesionales de ésta realizan las sesiones con los niños. Los dispositivos de la plataforma desarrollada se han instalado en esta sala de manera fija para facilitar la labor de los terapeutas y la adaptación de los usuarios, ya acostumbrados a trabajar en ella. En la Figura 7.1 se muestran diversas fotografías de la sala donde se lleva a cabo la experimentación. Se puede ver que la estancia dispone de varias zonas de trabajo donde los usuarios pueden desarrollar actividades de diferente fin. Se dispone también de multitud de materiales para realizar las tareas, por ejemplo de una zona con cuerdas atadas al techo, colchonetas, cama elástica, pelotas de pilates, materiales para tareas de psicomotricidad gruesa en general, pizarras, etc. Además, también se puede controlar la iluminación de la estancia para regular la intensidad o el color según el momento o la necesidad del niño, lo que permite crear diferentes ambientes cromáticos. Para ello las ventanas cuentan con paneles opacos que impiden la entrada de luz exterior cuando se requiere. La sala también dispone de hilo musical para reproducir música que pueda resultar agradable al usuario o ayudarlo a relajarse si es necesario, así como de un reproductor para visualizar contenido digital.

Los dispositivos de monitorización que forman parte de la plataforma se han instalado en diferentes puntos de la sala dependiendo de su uso. El dispositivo de adquisición de estímulos visuales se ha situado en la zona de pared que queda entre las ventanas y la pizarra grande, sobre un mueble y en una posición de media altura. De ese modo la cámara de 360 grados podrá captar la imagen de toda la sala, sea cual sea la zona donde se trabaje con el usuario. Este dispositivo se mantendrá fijo durante todas las sesiones de la experimentación en el mismo lugar. Sin embargo, tanto el dispositivo de adquisición de las condiciones del ambiente como el dispositivo de gestión y análisis del espectro de sonido varían su localización en la sala dependiendo de la zona de trabajo donde se encuentre el usuario, de manera que se sitúen cercanos a éste pero sin necesidad de que estén pegados a él. Por último, el dispositivo de monitorización personal se coloca en la muñeca del usuario durante toda la sesión lo más ajustado que el usuario sea capaz de tolerar.



Figura 7.1: Fotografías de la sala habilitada en la Clínica Universitaria para la realización de la experimentación.

7.1.2 *Protocolo para la adquisición de datos*

La planificación de las sesiones la realizan los especialistas de la clínica en base a cada usuario. Para cada sesión se definen una serie de tareas enfocadas a mejorar algún aspecto de su día a día, de una manera que el usuario se sienta cómodo trabajando en ello. Antes de iniciar con las tareas se inicia el registro de señales con los dispositivos. El procedimiento de puesta en funcionamiento es llevado a cabo por los especialistas de la clínica en todo momento, de manera que no hayan personas ajenas al usuario que dificulte la labor normal en la sesión.

En primer lugar, se coloca la pulsera de monitorización al usuario. En la primera sesión se le entrega y se deja que lo manipule para que se habitúe a él y ayude en la labor de conseguir que tolere su uso, tarea nada sencilla en algunos casos. Una vez se le ha colocado la pulsera lo más fijamente que permita el usuario, se encienden el resto de dispositivos y comienza el registro de las señales. A partir de ese momento los terapeutas comienzan las tareas definidas para trabajar con el usuario durante la sesión.

Al finalizar la sesión, se detienen todos los dispositivos y se le retira la pulsera de monitorización al usuario. Finalmente, los terapeutas generan un informe de la sesión donde se especifican las tareas llevadas a cabo, las horas de inicio de éstas y el comportamiento del usuario para cada una de ellas. En aquellas sesiones donde participa alguna persona extra, como puede ser el padre o la madre del usuario, también se especifica en el informe de la sesión. En la Tabla 7.1 se muestra un informe de una de las sesiones realizadas con un usuario. La información aportada en el informe facilita la tarea posterior de procesado y análisis de las señales. Además, ayuda a comprender posibles fallos en el sistema que pueden ser debidos a crisis en el usuario, por ejemplo rompiendo la pulsera de monitorización o arrancándosela de la muñeca y que se corte el registro de datos o se pierda la comunicación con el dispositivo de gestión. El desarrollo de la sesión mostrada en la tabla no contiene grandes incidentes, sin embargo, se producen algunas sesiones donde si aparecen dificultades grandes, ya sea para con los dispositivos o con la actitud del usuario.

Gracias a la arquitectura de trabajo de la plataforma, donde toda la información que recolectan los diferentes dispositivos de monitorización se almacena en la base de datos remota, se puede acceder a los datos registrados durante las sesiones en tiempo real. Esto permite seguir las sesiones desde un lugar diferente a la sala para no interferir en el trabajo de los terapeutas. De ese modo, ante cualquier posible problema que surja se

Fecha de la sesión	8/3/2021
Objetivos de la sesión	<ol style="list-style-type: none"> 1. Tolerar el estímulo a las tijeras. 2. Aumentar autonomía Actividades de la Vida Diaria (AVD) de aseo (ducha y lavado de manos): <ul style="list-style-type: none"> - Reconocer manchas. - Lavarse las manos con apoyo únicamente verbal.
Agenda de la sesión	<ol style="list-style-type: none"> a) [17:00 - 17:35] Circuito con cama elástica, picas, plastilina y cuchillo de plástico, y al final tendrá que recortar el papel, para hacer el mandala. b) [17:35 - 17:42] En la sala, enseñarle el material de los pictogramas del lavado de manos, y luego ir al aseo con el material. Dejar que ejecute la acción por ella misma con apoyo visual.
Desarrollo de la sesión	<p>Tolerar estímulo de las tijeras: Al cortar el mandala, realiza la presión para cortar, y una de las veces ha realizado el movimiento de arriba-abajo.</p> <p>Le hemos puesto celo en las uñas, pero no nos ha dejado cortarlo. Ha tolerado verlo en otra persona, y cortar ella misma el celo.</p> <p>Aumentar autonomía en AVD de aseo (ducha y lavado de manos): Mira los pictogramas y los entiende, pero le cuesta realizarlos.</p>

Tabla 7.1: Informe resumen de una sesión llevada a cabo con un usuario en la clínica.

tiene conocimiento directo de ello. Además, esto permite trabajar con los datos una vez finalizada cada sesión sin la necesidad de tener que molestar a los profesionales de la clínica con tareas de descarga o envío de datos.

7.1.3 Evolución de la experimentación durante las sesiones

La colaboración con la Clínica Universitaria continua actualmente durante la redacción de este documento y está previsto continuar con el registro de sesiones con la incorporación de nuevos usuarios.

Durante las sesiones llevadas a cabo con los diferentes usuarios se ha podido observar como cada vez más éstos se habituaban al uso de la pulsera y había una menor reticencia a utilizarlo. A pesar de las dificultades surgidas, los usuarios participantes han aceptado el uso desde el primer día pero si bien es cierto que en numerosas ocasiones han ocurrido incidentes durante el progreso de las sesiones, como por ejemplo arrancarse la pulsera del brazo. Esta actitud va mejorando con el paso de las sesiones pero existen días que en los que no están dispuestos a colaborar, siendo difícil tanto el trabajo habitual de las terapeutas como el registro de los datos.

El paso de las sesiones también ha permitido corregir los diferentes problemas que han ido surgiendo con el uso de la plataforma, problemas tanto técnicos, por ejemplo se han mejorado los servicios de comunicación, como problema de uso de los equipos

por parte de las terapeutas hasta habituarse al uso de los equipos. Esto último es muy importante, pues la plataforma se desea ceder también para uso doméstico y construir un sistema que sea sencillo para los padres o cuidadores de los usuarios es vital.

7.2 RESULTADOS DE LA EXPERIMENTACIÓN

En esta sección se muestran los resultados obtenidos en la experimentación con uno de los usuarios participantes. Se trata de una niña de 12 años con un grado de severidad alto en TEA.

El período total de registros de este usuario ha sido de algo más de cuatro meses, con una sesión cada semana y aproximadamente 35 minutos de registros por cada sesión. En total, el usuario participó en el estudio durante 16 sesiones, de las cuales 10 de ellas han sido válidas para la experimentación. Para las 6 sesiones restantes los registros están incompletos debido a problemas con el usuario durante la sesión o por fallos con alguno de los dispositivos de monitorización. El tiempo total de registros por tanto ha sido de 5 horas y 38 minutos de datos válidos. A continuación, en la Tabla 7.2 se muestra un resumen con algunos datos estadísticos básicos para cada una de las variables medidas, durante el conjunto global de las sesiones del usuario.

A partir de la tabla se pueden extraer algunos comentarios sobre las sesiones. Por ejemplo, con una luminosidad media de 32 luxes y máxima de solamente 163 luxes, se puede deducir que la intensidad lumínica durante las sesiones ha sido baja. En cambio, el sonido ambiente promedio registrado se sitúa en torno a los 60 dB-A, unos niveles de ruido no sumamente elevados pero sí han quedado registrados períodos con un ruido considerable. El resto de condiciones del ambiente (temperatura, humedad relativa y presión atmosférica) se mantienen estables dentro de un rango óptimo para que la estancia sea confortable, 24° de temperatura y 50 % de humedad, aunque llegando en algunos momentos por encima de los 25°. También se observa que el número medio de personas detectadas durante el desarrollo de las sesiones es de aproximadamente 3 personas, lo cual correspondería con la detección del usuario y las terapeutas, presumiblemente. Sin embargo, el valor máximo de personas detectadas por el dispositivo es de 5, probablemente en sesiones donde hayan participado los padres del usuario o algún otro profesional más de la clínica. Respecto al valor mínimo establecido de cero personas corresponde simplemente a registros iniciales donde el dispositivo no ha detectado persona, no es un valor a tener en cuenta a la hora

	Sonido (dB-A)	Frecuencia cardíaca (PPM)	Temperatura Corporal (°C)	Giroscopio (°/s)	Acelerómetro (G)	Flujo Óptico (cantidad de desplazamiento)	Número de personas	Luminosidad (lux)	Temperatura ambiente (°C)	Humedad relativa (%)	Presión atmosférica (mbar)
Valor promedio	59,21	63,37	33,37	56,85	2,08	0,003176	2,76	32,56	24,35	53,13	1010,28
Desviación estándar	9,27	13,41	1,87	40,15	0,39	0,002570	0,55	37,95	1,73	6,52	5,19
Valor mínimo	43,00	-	-	2,99	0,87	0,000478	1,00	0,00	20,31	37,82	1004,53
Cuantil 25	51,97	-	32,36	26,90	1,85	0,001242	2,00	0,00	23,40	47,45	1008,52
Cuantil 50	58,00	-	33,53	51,69	2,17	0,001796	2,00	40,00	24,01	55,98	1009,29
Cuantil 75	64,65	67,50	34,82	75,05	2,36	0,005071	3,00	55,00	25,46	58,57	1010,49
Valor máximo	86,93	120,00	36,52	347,28	2,83	0,012327	5,00	163,00	27,72	59,47	1024,46

Tabla 7.2: Resumen global de las variables en los registros tomados durante las sesiones en clínica del usuario descrito.

de procesar las señales. Por un motivo parecido se ha obviado incluir los valores mínimos de FC y de la temperatura corporal medidas, ya que los valores mínimos registrados por el sensor de FC corresponden a picos incorrectos debido a los ya comentados artefactos de movimiento, mientras que la temperatura corporal mínima registrada ocurren al inicio de los registros de cada sesión cuando el sensor todavía no ha alcanzado la temperatura del usuario. El valor medio de FC registrado por el sensor durante las sesiones ha sido de 63 PPM, un valor probablemente menor al real debido a los artefactos de movimiento. Sin embargo, el procesado de las señales para extraer los atributos y el modo de trabajo por diferencias solventan este problema, ya que el algoritmo no busca conocer el valor real sino los cambios que se producen. Por último, de los valores medios de las señales del giroscopio y del acelerómetro se puede extraer que el usuario mantiene una actividad alta durante las sesiones.

7.2.1 Procesado de las señales y generación del conjunto de datos

El procesado aplicado a las señales registradas durante las sesiones es el descrito en la Sección 6.1.1, donde también se describen los diferentes atributos generados a partir de ellas. Como resultado del procesado de las señales y la extracción de atributos se genera un conjunto de datos formado por 9942 entradas. Cada una de las entradas está a su vez compuesta por los 182 atributos diferentes, más una columna extra con una etiqueta de referencia. Esta etiqueta identifica la pertenencia de la entrada a un grupo de actividades desarrolladas.

A partir de los informes generados por los profesionales de la clínica, donde se describe la agenda de cada sesión y el desarrollo de éstas, se pueden extraer las

diferentes actividades que ha llevado a cabo el usuario durante las sesiones. Para plantear un punto de partida donde poder analizar el comportamiento del usuario frente posibles estímulos, se ha decidido agrupar todas esas actividades en cuatro grupos distintos según el nivel de estimulación y la intensidad de la tarea. En la Tabla 7.3 se muestra el listado con las diferentes actividades desarrolladas por el usuario durante la experimentación que se han incluido en cada uno de los grupos.

Las actividades del **Grupo A** se corresponden sobretudo al estímulo del usuario frente a las tijeras y cortar cosas con ellas. Se juega además con cambios en la intensidad lumínica y el color de la luz en la estancia para ver si mejora la tolerancia del usuario a los objetos con diferentes estímulos lumínicos.

Respecto al **Grupo B**, se encuentran las actividades donde el usuario mezcla el desarrollo de tareas de psicomotricidad gruesa, con actividad física, y tareas de psicomotricidad fina como son el uso de la plastilina o enfrentarse al estímulo de las tijeras y recortar objetos con ellas.

Por otra parte, las actividades del **Grupo C** están más enfocadas al aprendizaje, por ejemplo de las **AVD**, como conocer y comprender los pictogramas relacionados con el cuarto de baño. También se clasifican en este grupo las actividades relacionadas con aprender a tolerar el equipamiento sanitario u objetos que puede encontrarse en una consulta médica o un hospital.

La última de las categorías es el **Grupo D**, en ella se encuentran las actividades donde principalmente se llevan a cabo tareas físicas como es el resolver circuitos de obstáculos, y además se suele acompañar con música la actividad.

Una vez compuesto el conjunto de datos con las 183 columnas, se realiza una normalización aplicando la fórmula 6.8 a todos los atributos excepto al que identifica el número de personas en la estancia y al que identifica la banda de sonido dominante, a los cuales se les aplica la codificación *one-hot*. Por último, se revuelven las entradas del dataset antes de aplicar la división a éste para obtener el subconjunto de entrenamiento y el subconjunto de test. Para esta ocasión se ha aplicado una frontera del 80 % de los datos para entrenamiento y el 20 % restante para test. Sin embargo, en este caso también se va a aplicar la subdivisión al subconjunto de entrenamiento previamente. Para ello se realiza una división nuevamente al 80 % para entrenamiento y el 20 % restante del subconjunto para validación.

Si se analiza el valor de los diferentes atributos generados para diferentes entradas del dataset según el grupo de actividades en el que han sido clasificadas, se puede observar

	Tareas
Grupo A	<ul style="list-style-type: none"> - Recortar un puzle con las tijeras delante del usuario, y durante la actividad variar la luz de la estancia entre blanca y negra. - Distribuir diferentes objetos por el suelo, entre ellos unas tijeras, para que el usuario los recoja tratando de sentarse en posición de prono sobre una pelota. - Poner espuma sobre un perro de juguete e intentar que lo limpie, mientras en la estancia se pone luz negra. - Recortar un dibujo con un punzón. - Cortar el pelo a muñecos y realizar cortes en un folio con las tijeras. - Dibujar sobre papel para después recortarlo. - Extender plastilina sobre las tijeras. - Cortar imágenes de uñas.
Grupo B	<ul style="list-style-type: none"> - Resolver un circuito de juego con cama elástica, picas, plastilina y un cuchillo de plástico. Al finalizar el circuito el usuario tiene que recortar una figura de papel con las tijeras. - Saltar en la cama elástica con música o sentarse en el columpio. - Jugar con la plastilina intentando hacer formas sencillas como churros.
Grupo C	<ul style="list-style-type: none"> - Utilizando una plantilla de una boca con dientes, manchar algunos dientes con ketchup y pedir al usuario que señale cuáles están manchados. - Mostrar el material de los pictogramas del lavado de manos antes de ir al cuarto de baño a intentar que ejecute la acción por sí mismo. - Pintarse con pintalabios y sombra de ojos sobre el brazo, la mano, la cara, etc. Utilizando los pinceles de ojos simular pincharse en el brazo como si fuese una vacuna. - Simular situaciones de poner una vacuna, por ejemplo con una goma de borrar y un lápiz a modo de jeringuilla. - Simular manejo de aparatos relacionados con la sanidad como estetoscopios o termómetros de oído.
Grupo D	<ul style="list-style-type: none"> - Resolver un circuito de obstáculos con ladrillos, picas, el columpio, pelotas y una canasta. - Resolver un circuito de obstáculos mientras escucha música y le corta el pelo a un perro con pelos de la fregona.

Tabla 7.3: Listado de las actividades desarrolladas por el usuario durante las sesiones de la experimentación, clasificadas en cuatro grupos según el nivel de estímulo.

que existen diferencias entre ellas según el grupo de actividades al que pertenecen. En la Figura 7.2 se muestra una gráfica con el resultado de agrupar por el grupo de actividades de cada entrada algunos de los atributos generados a partir de diferentes señales medidas.

Si observamos los resultados de la FC se puede apreciar que el rango de la mayoría de valores se mantiene muy similar en los cuatro grupos de actividades. Sin embargo, se puede ver como en los grupos de actividades B y C el número de valores atípicos es muy superior a los otros dos grupos. Esto se debe a que en estos grupos (B y C), se agrupan la mayoría de actividades donde el usuario realiza tareas manuales constantes, como recortar, y con el movimiento constante de los dedos y la muñeca se producen más artefactos de movimiento que en los otros dos grupos. No obstante, si atendemos a los resultados de la señal del acelerómetro, se observa que el usuario realiza movimientos de los brazos constantemente durante las sesiones, aunque los valores de intensidad sí son mayores para los grupos B y D, cuyas actividades son de una intensidad en los movimientos más alta, ya que se encuentran dentro de estos grupos las tareas de psicomotricidad gruesa, como realizar circuitos de obstáculos. En línea con esto, también se aprecia esa mayor intensidad de movimientos en las actividades de los grupos B y D si nos centramos en los resultados de la señal de la temperatura corporal. Se puede ver como los valores de temperatura corporal son más bajos en estos dos grupos (B y D), ya que la temperatura corporal aumenta con la inactividad, y disminuye al aumentar la actividad motora. Por último, también se incluye el resultado de la temperatura ambiente como muestra de una señal medida sobre el entorno. Se observa por ejemplo en el grupo C que la temperatura corporal es más alta que en el grupo D a pesar de que la temperatura ambiente es menor en el grupo C. Esto afianza la relación acerca de la temperatura corporal y la actividad motora.

7.2.2 *Uso de algoritmos de AA para la extracción de información*

Una vez se dispone del dataset construido a partir de las señales registradas durante la experimentación, se va a tratar de extraer información subyacente de esos datos mediante el uso de algoritmos de AA. Para esta tarea se van a utilizar métodos de aprendizaje no supervisado, ya que no se dispone de información del usuario o su comportamiento más allá de la proporcionada por los informes de las sesiones realizadas. Por ello, las etiquetas generadas con el grupo de actividades al que

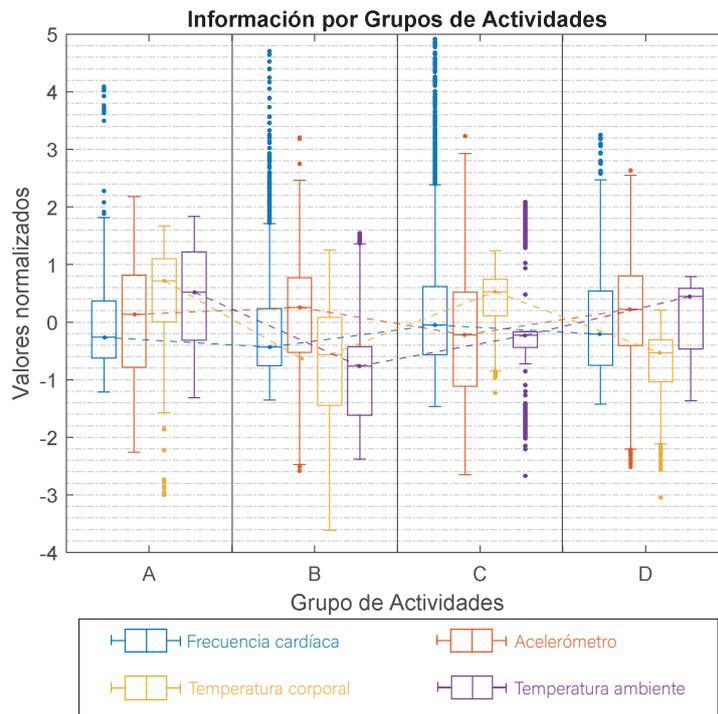


Figura 7.2: Algunos de los atributos generados con las señales obtenidas durante la experimentación. Se representan los valores normalizados para los diferentes grupos de actividades mediante el valor de la mediana y la caja de error cuyos extremos representan el primer y tercer cuartil.

pertenecen las entradas del dataset únicamente se utilizarán para validar los resultados obtenidos con los algoritmos que se utilicen.

En primer lugar, se van a aplicar métodos para la reducción de la dimensionalidad al conjunto de datos, lo que permitirá a los diferentes algoritmos posteriores trabajar más rápidamente y además es probable que algunos de ellos no aporten información valiosa. El primero de los métodos aplicados ha sido el de [PCA](#). El resultado de aplicar este algoritmo se muestra en la [Tabla 7.4](#). Vemos que con los primeros 50 componentes principales calculados ya se mantiene casi un 95 % de la varianza de los datos originales. Únicamente utilizando los 10 primeros componentes ya se conservaría más del 65 % de los datos, y los dos primeros recogen más del 30 %. En la [Figura 7.3](#) se muestra la distribución en el espacio utilizando los dos primeros vectores resultado de aplicar el algoritmo [PCA](#) a las etiquetas de grupo del subconjunto de entrenamiento. Se puede ver como con únicamente dos componentes es capaz de separar las diferentes entradas del subconjunto.

Número de componentes principales	Varianza capturada (%)
10	66,86
20	77,56
50	94,95
100	99,99
182	100

Tabla 7.4: Varianza de los datos originales capturada por diferente número de [PCA](#).

Además del [PCA](#), también se han aplicado otros algoritmos para la reducción de la dimensionalidad como son el [PCA](#) incremental, el [PCA](#) disperso, la Descomposición en Valores Singulares y la Proyección Gaussiana Aleatoria. Sin embargo, el resultado de estos algoritmos ha sido muy similar al encontrado con el [PCA](#) como se puede observar en la Figura 7.4. Por lo tanto, se ha seguido trabajando con los resultados obtenidos con éste ya que es más sencillo por lo que los tiempos de ejecución son mucho menores que en otros más complejos.

El siguiente paso que se ha realizado es aplicar algoritmos de *clustering* para tratar de identificar aquellas entradas del conjunto de datos que sean similares entre sí. Para ello se continuará trabajando con los vectores de atributos extraídos previamente del algoritmo [PCA](#).

Para comenzar con ello, se empieza aplicando el algoritmo de *K-Means*. Para ello es necesario especificar el número de clústeres en los que queremos que el algoritmo agrupe las entradas del conjunto de datos. El algoritmo tratará de optimizar el modelo minimizando la variación de los datos dentro de cada clúster, conocido como *inercia*. Lo que se ha realizado en primera instancia es un barrido de un rango de clústeres para ver como se reduce la inercia a medida que aumenta el número de clústeres. En la Figura 7.5a se puede observar esto. El mecanismo que se suele emplear para seleccionar el número óptimo de clústeres es coger el número que se encuentra donde la curva forma un "codo", es decir un cambio brusco en la pendiente. Sin embargo, en esta ocasión nos encontramos con una parábola que decrece más o menos progresivamente sin formar ese "codo". Otra manera de comprobar cómo aumentando el número de clústeres mejora el resultado, es decir, los diferentes grupos serán más homogéneos, es calculando la exactitud utilizando como referencia las etiquetas generadas con los diferentes grupos de actividades. En la Figura 7.5b se muestra la exactitud global del

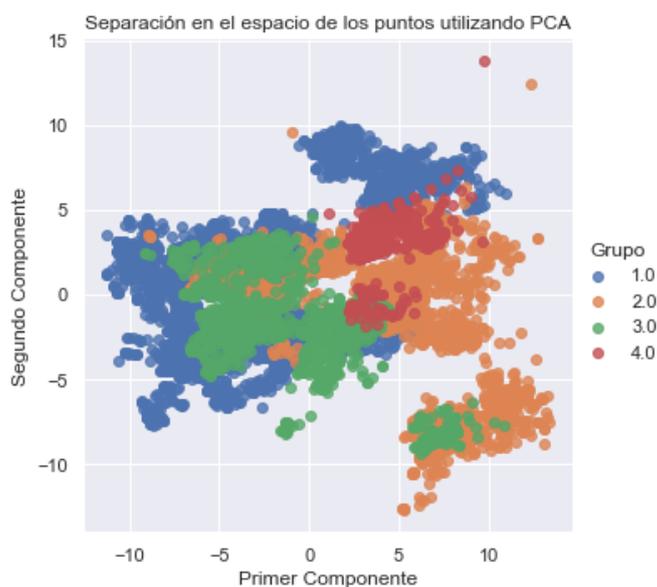


Figura 7.3: Distribución en el espacio de las etiquetas de grupo de tarea utilizando los dos primeros vectores resultado de aplicar el algoritmo PCA.

Nº Clúster	Exactitud						
1	0,99	6	0,57	11	1,00	16	0,63
2	0,73	7	1,00	12	0,96	17	0,70
3	0,98	8	1,00	13	0,83	18	0,64
4	0,84	9	0,72	14	0,94	19	0,51
5	0,76	10	0,79	15	0,81	20	0,67

Tabla 7.5: Resultados de la exactitud individual de cada clúster con el algoritmo *K-Means*.

modelo para un número diferente de clústeres. Efectivamente la exactitud aumenta al aumentar el número de clústeres. Cabe destacar que el modelo no ha sido entrenado con las etiquetas de grupo de actividad, por lo que ha sido el modelo el que ha extraído una estructura subyacente a partir del conjunto de datos. Además, si evaluamos el comportamiento de cada clúster de manera individual, para un total de 20, encontramos que algunos tienen una exactitud del 100 % o cercano a éste. En la Tabla 7.5 se muestra la exactitud para cada uno de los 20 clústeres de manera individual. Lo que representa, es la homogeneidad de los datos agrupados en cada uno de los clústeres. Si se fija el número de clústeres a únicamente 4, es decir, el número de grupos en los que se dividieron las actividades de la experimentación, la exactitud de esos cuatro clústeres se reduce en gran medida respecto de la mostrada en la tabla.

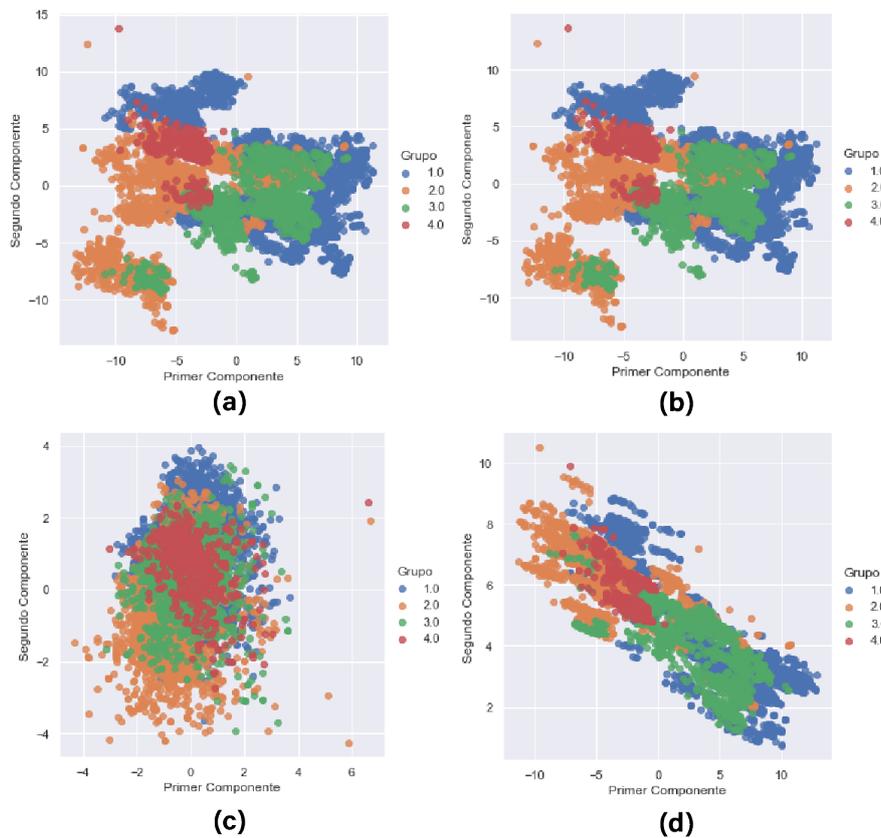


Figura 7.4: Distribución en el espacio de las etiquetas de grupo de tarea utilizando los dos primeros vectores resultado de aplicar diferentes algoritmos de reducción de la dimensionalidad. **(a)** *Incremental PCA*. **(b)** *PCA disperso*. **(c)** *Proyección Gaussiana Aleatoria*. **(d)** *Descomposición en Valores Singulares*.

Por otro lado, se ha probado también con el algoritmo de *clustering* jerárquico. En esta ocasión no es necesario indicar el número de clústeres para el entrenamiento, sino que el algoritmo generará un dendrograma con un número de clústeres igual al total de entradas del conjunto de datos, y posteriormente se decide por donde se desea cortar. De esa manera, según por donde se decida cortar, se fijará un número de clústeres. Como resultado de aplicar el algoritmo se obtienen las distancias que separan un clúster de nivel inferior, el cual posee un menor número de entradas asignadas a él, con un clúster de nivel superior donde se incluyen un número mayor de entradas. En la Tabla 7.6 se puede observar mejor esto. Se muestran los 10 primeros y los 10 últimos clústeres generados por el algoritmo en la parte inferior y superior respectivamente del dendrograma. En el punto inicial del dendrograma los diferentes clústeres se encuentran muy cercanos entre sí y el algoritmo une dos a dos los valores del conjunto formando

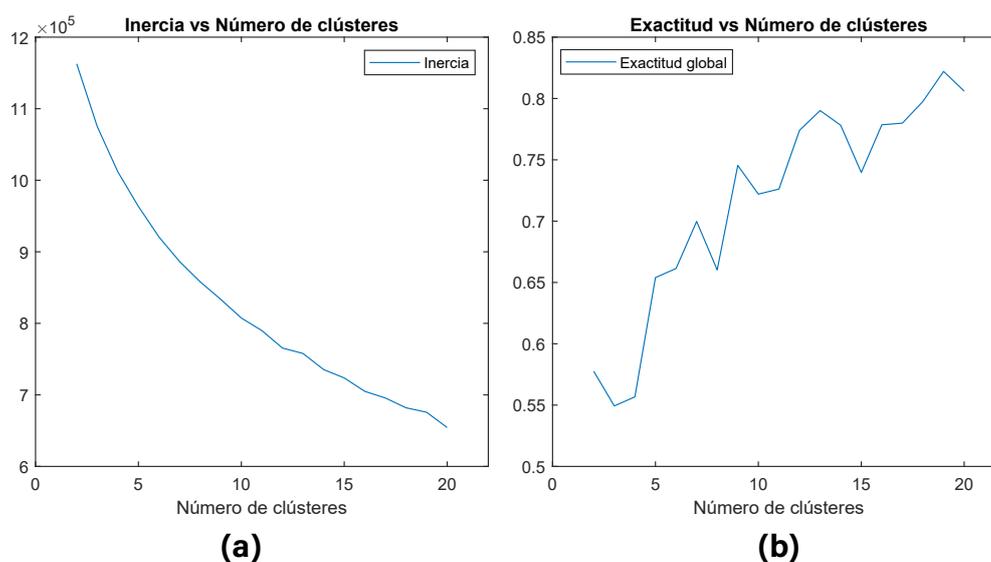


Figura 7.5: **(a)** Gráfica resultado de la inercia del algoritmo *K-Means* según el número de clústeres utilizados en el entrenamiento. **(b)** Gráfica de la exactitud global del modelo en función del número de clústeres utilizado.

clústeres muy pequeños. A medida que se va ascendiendo por el dendograma, la distancia entre los clústeres generados por el algoritmo va creciendo y el número de entradas que forma cada clúster nuevo también aumenta. Finalmente, el último clúster reúne a todas las entradas del conjunto de datos. Las dos primeras columnas de la tabla identifican los clústeres que se están uniendo entre sí para formar el nuevo. En los primeros componentes la identificación corresponde a una entrada del conjunto inicial de datos de entrenamiento, después la identificación corresponde a un clúster nuevo generado.

Ahora es cuando se debe seleccionar por qué parte del dendograma creado por el algoritmo se desea cortar. Para ello, se debe determinar qué distancia euclidiana será la máxima que se permite entre dos clústeres. Para comparar los resultados con el modelo anterior vamos a fijar una distancia para la cual el número de clústeres sea 20. Para los resultados obtenidos, se debe fijar una distancia máxima entre clústeres de 151.5. La exactitud global del modelo para esta elección es de un 81,57%. En cuanto a la exactitud individual de cada uno de los clústeres, se muestra en la Tabla 7.7.

Finalmente, se han aplicado también dos algoritmos más de clustering como son el *DBSCAN* y el *HDBSCAN*, una versión del *DBSCAN* jerárquica. Sin embargo, los resultados alcanzados con estos algoritmos han sido peores que con los algoritmos anteriores (49,31 % y 68,86 % de exactitud, respectivamente). Para tratar de profundizar

	Clúster 1	Clúster 2	Distancia	Tamaño	Clúster 1	Clúster 2	Distancia	Tamaño	
1	4097	4098	0.0	2	7986	15965	15977	208,06	629
2	4108	4109	0.0	2	7987	15958	15978	220,46	879
3	256	257	0.0	2	7988	15976	15982	222,66	1728
4	4116	4117	0.0	2	7989	15981	15983	241,24	1935
5	1030	1031	0.0	2	7990	15945	15979	257,33	1920
6	4124	4125	0.0	2	7991	15980	15984	292,84	1615
7	515	516	0.0	2	7992	15975	15986	307,65	2734
8	2064	2065	0.0	2	7993	15985	15987	356,03	3648
9	4131	4132	0.0	2	7994	15988	15989	416,88	4349
10	4133	8005	0.0	3	7995	15990	15991	602,59	7997

Tabla 7.6: Fragmento de la matriz resultado del dendograma generado por el algoritmo de clustering jerárquico.

más es necesario obtener mayor información del usuario y de de su comportamiento. De ese modo, se podrán aplicar algoritmos para la detección de anomalías, combinar un aprendizaje semi-supervisado y establecer situaciones que debamos detectar.

Nº Clúster	Exactitud						
1	0,98	6	0,81	11	1,00	16	0,88
2	0,76	7	0,51	12	0,42	17	0,83
3	0,83	8	0,88	13	1,00	18	0,37
4	0,81	9	1,00	14	1,00	19	0,63
5	0,75	10	1,00	15	0,98	20	0,63

Tabla 7.7: Resultados de la exactitud individual de cada clúster con el algoritmo de clustering jerárquico.

7.3 APLICACIÓN PARA LA DIVULGACIÓN DINÁMICA DE RESULTADOS

Una de las principales características de la plataforma desarrollada es que toda la información recolectada por los dispositivos de monitorización se encuentra almacenada de una manera estructurada en una base de datos remota. Esto permite que se pueda acceder a ella de manera rápida desde cualquier lugar y en cualquier momento. Aprovechando esta cualidad se ha desarrollado una aplicación web para visualizar los datos adquiridos durante las sesiones de la experimentación y los resultados obtenidos con los registros.

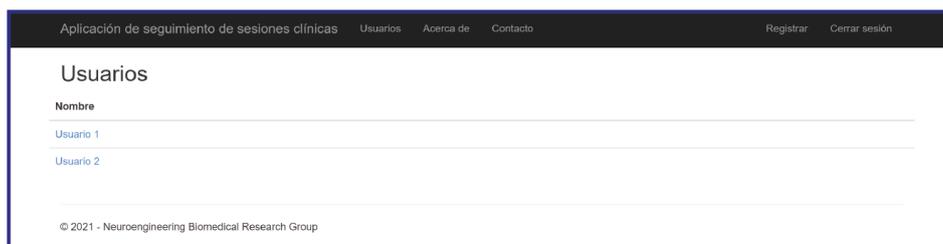


Figura 7.6: Imagen de la página inicial de la aplicación web desarrollada para consultar los registros y resultados de la experimentación.

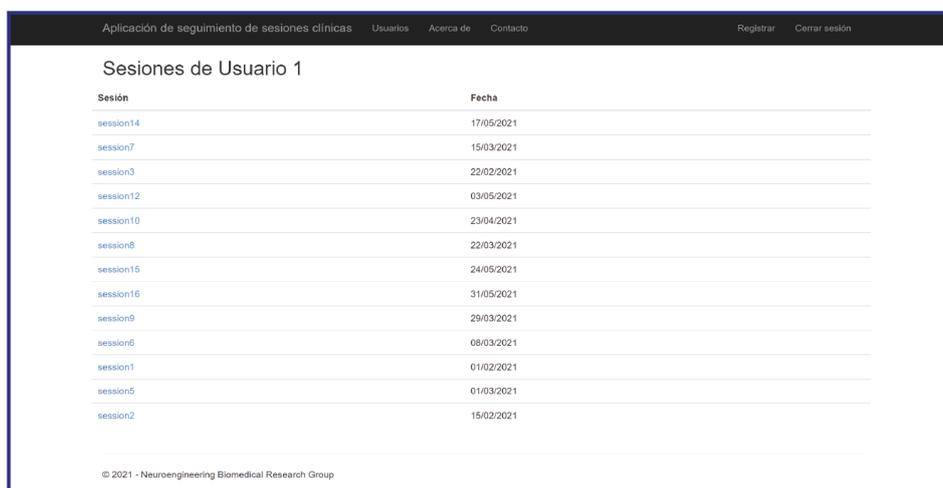
En la Figura 7.6 se muestra una imagen de la portada de la aplicación web. La interfaz inicial muestra una imagen de portada y una barra de navegación superior con diferentes botones para cambiar entre las diferentes páginas de la aplicación. Existen dos páginas secundarias, una de "Acerca de" donde se describe el propósito de la aplicación y otra de "Contacto" donde aparece información para contactar con los investigadores responsables en caso de ser necesario o tener interés en el proyecto. Por último, la página principal de la aplicación, llamada "Usuarios" y que para acceder a ella es necesario iniciar sesión con unas credenciales válidas.

A pesar de que los datos de la experimentación son tratados de manera anónima, es necesario proteger la información y por ello es necesario realizar una gestión de cuentas con diferentes permisos de acceso. Existen tres tipos diferentes de cuentas dentro de la aplicación. Por un lado, las cuentas de *administrador*, que tienen acceso a todos los usuarios, permisos para editar los usuarios y las sesiones de cada uno de ellos, pueden registrar nuevas cuentas de usuario de cualquier tipo y además tienen la posibilidad de descargar los registros de las sesiones generando un archivo de valores separados por comas o CSV. El segundo tipo de cuenta que permite la aplicación son las cuentas de *terapeuta*, que tienen acceso a todos los usuarios y las sesiones de cada uno, así como a descargar los registros de las sesiones en archivos CSV, pero no pueden editar los usuarios ni pueden gestionar las cuentas de usuarios de acceso a la aplicación web. El último de los tipos de cuenta de usuarios de la aplicación son las cuentas de tipo *usuario*, que están pensadas para compartirla con los padres o tutores de los usuarios participantes en la experimentación y únicamente tienen acceso al usuario

correspondiente a su hijo o persona a su cargo. Existe un segundo caso de la cuenta *usuario*, donde se puede dar acceso a los registros de más de un usuario participante. Se trata de una cuenta generada para investigadores interesados en colaborar en el proyecto o terceras personas que se les quiera compartir la información. En cualquier caso, ninguna de las cuentas de tipo *usuario* tendrá acceso a la gestión de cuentas de acceso o la descarga de los registros.



(a)



(b)

Figura 7.7: (a) Imagen de la página de “*Usuarios*” donde se muestra el listado de los usuarios disponibles. (b) Imagen de la página “*Usuarios*” donde se muestra el listado de las sesiones de uno de los usuarios disponibles.

Una vez identificado en la aplicación con las credenciales, al acceder a la pestaña “*Usuarios*” se listan todos los usuarios a los que tiene acceso la cuenta (Figura 7.7a). Al seleccionar sobre uno de los usuarios disponibles se carga la lista de sesiones disponibles de ese usuario, identificadas por un nombre de sesión y la fecha en la que se llevó a cabo. En la Figura 7.7b se muestra un ejemplo de esto, donde se puede ver el listado de sesiones disponibles de un usuario. Si se selecciona sobre una de las sesiones, por defecto se cargará la vista de *Gráficas* de esa sesión, donde se muestra una gráfica

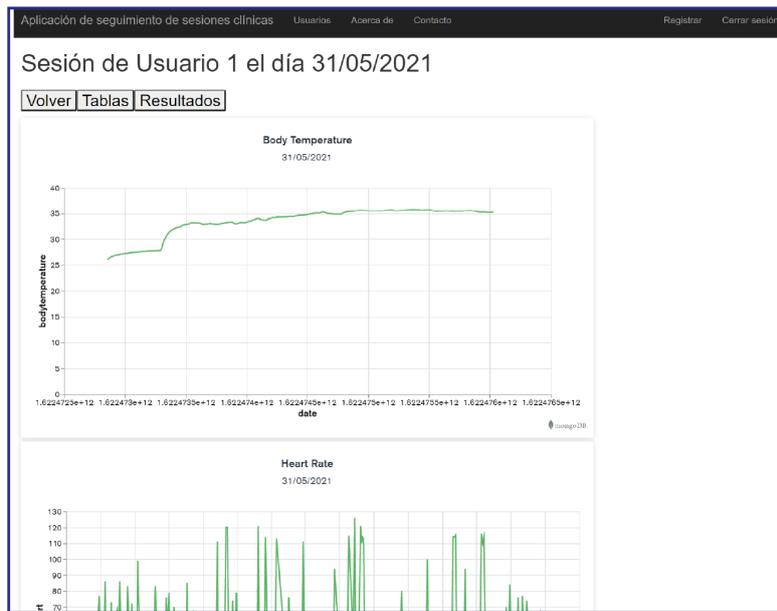
con cada una de las señales medidas. Se puede ver un ejemplo de esto en la Figura 7.8a. En la parte superior aparece diferentes botones debajo de la identificación de la sesión que permiten cambiar entre la vista de *Gráficas*, la de *Tablas* y la vista de resultados. Si se pulsa sobre el botón de *Tablas* se muestra una vista con los valores de las diferentes señales en diferentes listas con el valor del registro y la fecha de lectura de éste. Se muestra un ejemplo de la vista de *Tablas* en la Figura 7.8b. Se ve como además aparece la opción de exportar los datos de la tabla a un archivo CSV. Por último, si se selecciona sobre el botón de *Resultados* la aplicación abrirá una vista donde se muestra la tabla de resultados de la sesión con algunos parámetros estadísticos de las diferentes señales. En la Figura 7.8c se muestra una captura de los resultados mostrados en la aplicación para una sesión.

7.4 CONCLUSIONES DEL CAPÍTULO

En este capítulo se presenta una experimentación llevada a cabo con personas con TEA en un entorno clínico controlado con profesionales especialistas. Se ha mostrado la configuración del entorno donde se llevan a cabo las sesiones con los usuarios, cómo y donde se han instalado los dispositivos de monitorización de la plataforma y cuál es el protocolo para la adquisición de las señales con los equipos.

Por otro lado, se han expuesto los resultados obtenidos de la experimentación con uno de los usuarios participantes. Se han analizado las señales obtenidas, se han calculado atributos a partir de estas señales y posteriormente se han aplicado algoritmos de AA para extraer información a partir de los datos registrados por los dispositivos de monitorización.

Finalmente, se presenta una aplicación web que permite compartir de manera dinámica los registros tomados durante las sesiones y los resultados de éstas con los terapeutas o los padres o cuidadores de los usuarios si lo desean.



(a)

Aplicación de seguimiento de sesiones clínicas Usuarios Acerca de Contacto Registrar Cerrar sesión

Sesión de Usuario 1 el día 31/05/2021

Volver Gráficas Resultados

Valores Temperatura Corporal Exportar datos ...

ID	Date	Time
33.1300010881152	31/05/2021	18:05:49
33.1199989318847	31/05/2021	18:06:00
33.1100006103515	31/05/2021	18:06:09
33.0899998948242	31/05/2021	18:06:19
33.0899998948242	31/05/2021	18:06:32
33.0900001525879	31/05/2021	18:06:40
33.0800018310546	31/05/2021	18:06:49
33	31/05/2021	18:07:00
32.9399988267089	31/05/2021	18:07:09
32.849998474121	31/05/2021	18:07:19
32.8300018310546	31/05/2021	18:07:30
32.8600008103515	31/05/2021	18:07:39
32.8899993898484	31/05/2021	18:07:49
32.9500007629394	31/05/2021	18:08:02
32.9700012207031	31/05/2021	18:08:09
33.0099983215332	31/05/2021	18:08:19
32.9599990844728	31/05/2021	18:08:30

Valores Frecuencia Cardiaca Exportar datos ...

(b)

Aplicación de seguimiento de sesiones clínicas Usuarios Acerca de Contacto Registrar Cerrar sesión

Sesión de Usuario 1 el día 31/05/2021

Volver Gráficas Tablas

	Sound (dB)	Heart rate (BPM)	Body Temperature (°C)	Gyroscope Module (deg/s)	Accelerometer Module (G)	Optical Flow (Quantity of displacement)	People detected (% of people)	Luminosity (lux)	Environmental Temperature (°C)	Relative Humidity (%)	Atmospheric Pressure (mBar)
mean	55.18	55.93	34.31	51.27	2.14	0.003356	1.88	18.41	25.45	58.37	1005.73
std	5.94	15.95	1.31	40.35	0.39	0.002130	0.60	21.61	0.06	0.27	0.18
min	46.53	-	-	3.83	1.06	0.008989	1.00	0.00	25.38	57.90	1005.49
25%	50.33	-	33.14	14.08	1.92	0.002201	2.00	0.00	-	-	-
50%	54.25	-	34.82	46.01	2.22	0.002979	2.00	0.00	-	-	-
75%	60.09	64.50	35.50	77.26	2.43	0.003401	2.00	44.26	-	-	-
max	71.06	120.00	35.74	231.52	2.76	0.009768	4.00	45.67	25.52	58.77	1005.98

* mean = valor medio; std = desviación estándar; min = valor mínimo; 25%, 50%, 75% = cuantil 25, 50 y 75 respectivamente; max = valor máximo.

Sesión de Usuario 1 el día 31/05/2021

© 2021 - Neuroengineering Biomedical Research Group

(c)

Figura 7.8: (a) Imagen de la aplicación web donde se muestran los registros de una sesión en modo *Gráficas*. (b) Imagen de la aplicación web donde se muestran los registros de una sesión en modo *Tablas*. (c) Imagen de la aplicación web donde se muestran resultados de una sesión en la pestaña *Resultados*.

ALGORITMO PARA LA RECONSTRUCCIÓN DE LA FRECUENCIA CARDÍACA EN TAREAS CON ARTEFACTOS DE MOVIMIENTO MEDIANTE APRENDIZAJE AUTOMATIZADO

En este capítulo se presenta un método desarrollado para reconstruir la señal de la frecuencia cardíaca del individuo cuando ésta se corrompe debido a los artefactos de movimiento. Para ello se emplean diferentes algoritmos de AA previamente expuestos. En la primera parte del capítulo se muestra la importancia de la frecuencia cardíaca dentro de la plataforma desarrollada y se analizan los métodos disponibles en la literatura para atajar el problema. Más tarde se presenta el método propuesto y el procedimiento llevado a cabo para implementarlo y finalmente, se muestran los resultados alcanzados con el algoritmo propuesto.

8.1 RELEVANCIA DE LA FRECUENCIA CARDÍACA Y PROBLEMÁTICA DE LA SEÑAL DE FOTOPLETISMOGRAFÍA

Como ya se introdujo en la Sección 3.2.2, la FC es una variable muy importante dentro de la plataforma desarrollada. La FC proporciona información sobre el estado del usuario, reflejando las alteraciones debido a la actividad física, a cambios en la conducta o a un aumento del estrés, por ejemplo. Es el indicador principal que posee el sistema para medir cuando el individuo sufre un cambio repentino ya que la señal reacciona rápidamente en el tiempo ante los cambios, y junto con la información aportada por el resto de variables se puede estimar el posible motivo de ese cambio en el sujeto.

Por otra parte, el instrumento utilizado para medir la FC dentro de la plataforma presentada es el sensor de PPG integrado en el dispositivo de monitorización personal (Capítulo 3). A partir de la señal de PPG medida por el sensor sobre la muñeca del usuario, se realiza un filtrado de ésta y se extrae la FC en ventanas de 6 segundos.

Sin embargo, debido a que la señal de PPG es muy sensible a los movimientos del brazo, de la muñeca y de los dedos del usuario, en aquellos momentos en los que el

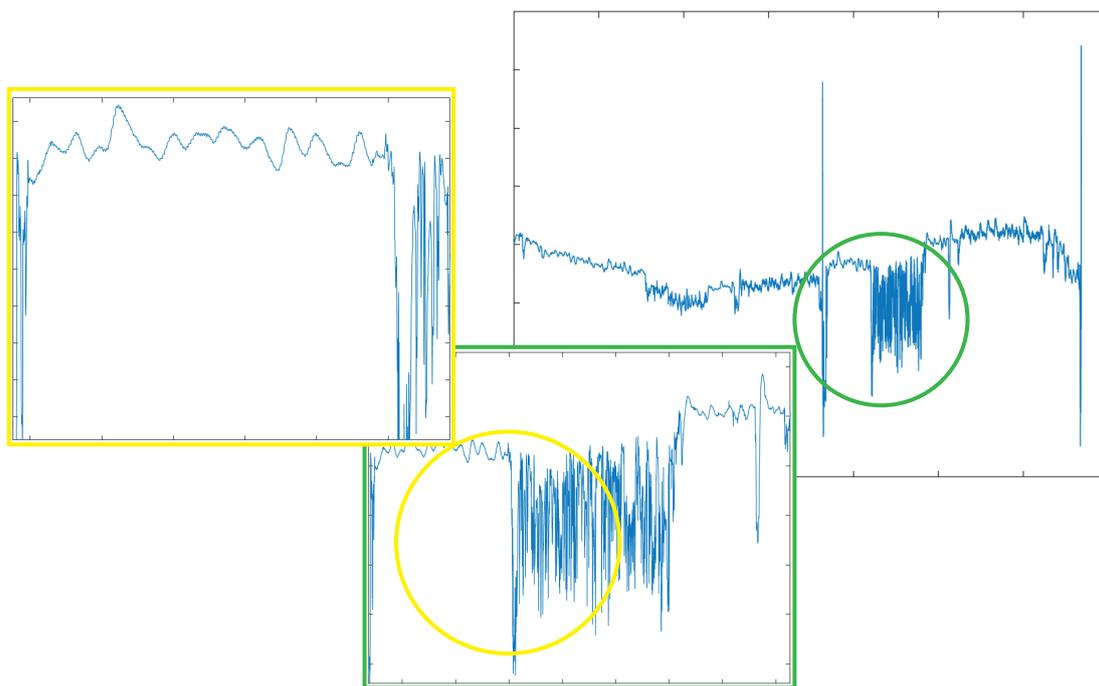


Figura 8.1: Gráfica de la señal de PPG durante una sesión de prueba.

usuario está llevando a cabo tareas que impliquen movimientos constantes de alguna de estas partes, la señal de PPG se corrompe y por tanto la FC que se obtiene también queda alterada (Bent et al., 2020). Además, debido a las características especiales de los usuarios con TEA para los que ha sido desarrollado el dispositivo de monitorización de señales fisiológicas, éste queda sujeto a la muñeca del usuario de una manera suave puesto que una fijación excesivamente fuerte puede suponer que el individuo no tolere el uso del sistema. Esto implica que la intensidad de la señal puede ser más baja de lo deseado y hará que todavía sea más susceptible a los posibles movimientos del usuario. Estas circunstancias pueden suponer que la señal de la FC que se obtiene del usuario durante un período de monitorización esté parcialmente corrupta o incluso casi en su totalidad si el sujeto no está dispuesto a colaborar y además las tareas desarrolladas son muy activas.

Un ejemplo de este problema se puede encontrar en la Figura 8.1, donde se muestra una gráfica con la señal de PPG medida sobre la muñeca de un usuario durante una sesión de prueba. Se puede ver como la forma de la señal cambia a lo largo de la sesión a medida que el individuo realiza diferentes actividades. Al ampliar sobre una de las zonas de cambio entre actividades se observa como de una señal limpia donde

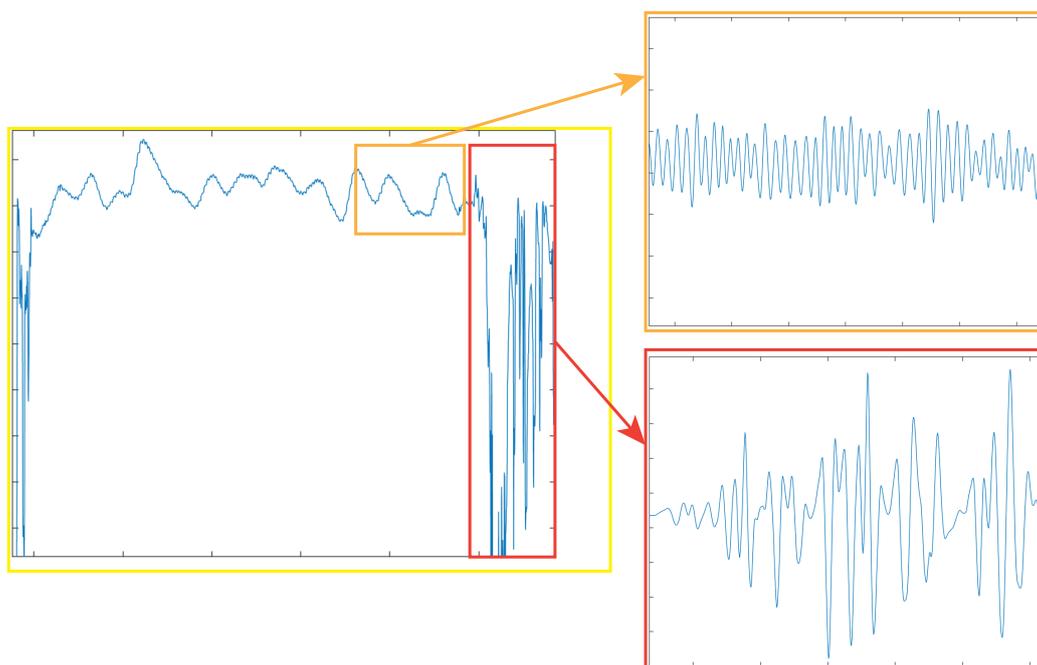


Figura 8.2: Gráficas resultado de la aplicación del filtrado a la señal original de PPG en períodos con dos actividades diferentes.

únicamente existe un ruido de muy baja frecuencia, fácil de eliminar, se pasa a una señal totalmente alterada donde el ruido pasa a formar casi en su totalidad la señal.

Si tratamos de aplicar el filtrado de señal planteado en la Sección 3.2.2, donde se muestra el diseño del sensor de FC, a la parte ampliada de la sesión (rectángulo amarillo) encontraremos resultados diferentes para las distintas aplicaciones realizadas. En la Figura 8.2 se muestra el resultado de aplicar esto a dos ventanas diferentes de datos. Por un lado, tenemos la ventana correspondiente a una actividad de bajo nivel de movimiento (rectángulo naranja). Se puede observar como tras aplicar los diferentes filtros a esta parte de los datos originales se obtiene una señal limpia, de aspecto sinusoidal y donde se puede calcular la FC con una confianza en el valor alta. Sin embargo, si aplicamos los mismos filtros a una ventana correspondiente a una actividad donde el usuario ha realizado movimientos constantes del brazo, la muñeca o los dedos (rectángulo rojo), la señal que se obtiene está corrupta y por tanto, el cálculo de la FC tendrá un resultado probablemente alejado del valor real y con una confianza muy baja.

8.1.1 Métodos para la eliminación de artefactos de movimiento en la señal de PPG

En la literatura existen multitud de trabajos donde se presentan soluciones para la eliminación de los artefactos de movimiento en la señal de PPG. Uno de estos trabajos es el desarrollado en (Zhang et al., 2019). En él se propone un algoritmo para eliminar los artefactos de movimiento basado en el uso de múltiples sensores de PPG con una diferentes longitudes de onda, uno de ellos verde que será el encargado de medir la señal de PPG del usuario, y otro infrarrojo cuya señal se utilizará como referencia del movimiento. El método propuesto realiza un proceso de eliminación del movimiento basado en la transformada continua en ondículas, o *Continuos Wavelet Transform*, seguido de la estimación de la FC y la reconstrucción de la señal. Los autores muestran unos resultados con bajo error absoluto medio en usuario sanos realizando diferentes actividades con un baja intensidad física. Otro trabajo destacado de la literatura que utiliza diferentes longitudes de onda es el llevado a cabo en (Lee et al., 2020). En este caso, los autores plantean el uso de múltiples sensores (4) orientados en diferentes direcciones que a su vez tienen múltiples canales de PPG, uno rojo, uno verde y uno infrarrojo. Además, también incorporan una IMU para adquirir la señal de aceleración. Cuando la presencia de movimiento es pequeña o nula, la FC se calcula a partir de la señal de PPG del sensor verde. En presencia de movimientos, la señal de PPG es una mezcla de los diferentes sensores que se encuentran orientados en distintas direcciones y que miden diferentes profundidades según la longitud de onda. Para extraer el componente pulsátil de cada sensor emplean un algoritmo de análisis de componentes independientes. Finalmente se aplica la FFT a la componente con un valor medio más grande para hallar la FC.

Por otra parte, también existen trabajos con una propuesta diferente, donde destaca el uso de un acelerómetro para eliminar los artefactos de movimiento. En el trabajo desarrollado en (M. Wang et al., 2019), se propone un método que combina la estimación de la FC con un filtrado *notch*. En primer lugar, se aplica una cancelación adaptativa del ruido basada en el algoritmo de medias de mínimos cuadrados, o LMS por sus siglas in inglés, que reduce los artefactos de movimiento de una manera preliminar utilizando las señales de aceleración de los tres ejes (x, y, z) junto con la señal de PPG. Finalmente, aplica un filtro *notch* para sustraer las frecuencias asociadas a los artefactos de movimiento de la respuesta en frecuencia de la señal de PPG, obteniendo por separado una señal sin ruido. Un trabajo similar se lleva a cabo en (Zhu et al., 2019). Los autores presentan un nuevo algoritmo basado en la sustracción espectral.

Para ello se estima la componente espectral de los artefactos de movimiento a partir de las señales de aceleración de los tres ejes (x , y , z), y se eliminan esas componentes de la respuesta en frecuencia de la señal de PPG. De esa manera se eliminan los picos en la respuesta en frecuencia provocados por los artefactos de movimiento.

Un recorrido diferente a las técnicas anteriormente descritas es el uso del AA para la detección de la FC a partir de una señal de PPG. En el trabajo presentado en (Essalat et al., 2017) se plantea el uso de aprendizaje supervisado mediante redes neuronales para atacar el problema sin la necesidad de utilizar señales de aceleración. Se seleccionan diferentes picos dentro del espectro en frecuencia de la señal de PPG sin procesar y se les asigna una probabilidad de que cada pico corresponda con el pico de la FC. A continuación, se extraen y seleccionan los atributos para entrenar una red neuronal de tres capas con 22 neuronas en la capa oculta que será la encargada de estimar el valor de la FC. Otro trabajo que utiliza técnicas de AA es (Biswas et al., 2019). En él, se plantea el uso de una red neuronal profunda de cuatro capas, dos de ellas de red neuronal convolucional, junto con dos capas de memoria a corto plazo o *long short-term memory (LSTM)*, seguido de una capa densa de salida que actúa como capa de regresión con una sola neurona, para predecir el valor de la FC a partir de la señal de PPG.

8.1.1.1 *Uso de los métodos existentes en el sistema desarrollado*

Los trabajos analizados de la literatura se enfocan en eliminar los artefactos de movimiento de maneras diferentes. Comenzando por el último grupo revisado, los métodos que utilizan técnicas de AA como son las redes neuronales profundas, requieren de un gasto computacional muy alto, sobretodo si se complican con el uso de capas convolucionales o LSTM. La complejidad de llegar a implementar esas soluciones en sistemas wearables para que trabajen en tiempo real no es tarea sencilla.

Por otro lado, los trabajos que tratan de aprovechar la señal proporcionada por múltiples sensores y canales de diferentes longitudes de onda para la medida de la señal de PPG no son viables de implementar dentro de la plataforma desarrollada en este trabajo. El dispositivo de monitorización ha sido desarrollado atendiendo a las características especiales de los usuarios, personas con TEA, y añadir nuevos sensores que hagan crecer el tamaño del dispositivo actual no es la solución, además de no asegurar que la señal obtenida sea mejor debido a la complejidad para con los usuarios.

Lo que si dispone el dispositivo de monitorización es de una **IMU** que proporciona la señal de aceleración de los tres ejes (x, y, z). Por tanto, aquellos métodos que tratan de sustraer los artefactos de movimiento a partir de las señales de aceleración sí pueden ser implementados en el sistema. Sin embargo, este tipo de soluciones no suelen tener en cuenta todas las propiedades de la medida de **PPG**, ya que existe un grupo de movimientos, al que podemos denominar micromovimientos, en el que se encuentran los movimientos de los dedos como son el golpeteo o la apertura y cierre del puño, que no implican el movimiento del brazo.

El sensor de **PPG** utiliza la detección por reflexión. Este principio se describe mediante la ley de *Beer-Lambert* (*Swinehart, 1962*), a partir de la cual se define la medida de **PPG** en la Ecuación 8.1, donde I_i e I_o son las intensidades de entrada a la piel y la de salida reflejada, respectivamente; la ε representa el coeficiente de reflexión/absorción de los diferentes tejidos; c es las concentraciones de los diferentes tejidos y d representa la longitud del camino de la luz reflejada. Por lo tanto, la ε y la d dependen de la longitud de onda de la luz, mientras que la c y también la d podrán variar en el tiempo si se producen movimientos.

$$I_o = I_i \cdot \exp \left(- \sum_{j=1}^n \varepsilon_j \cdot c_j(t) \cdot d_j(t) \right) \quad (8.1)$$

Atendiendo a la ecuación 8.1, existen por tanto dos fuentes principales de los artefactos de movimiento. Por un lado, el desplazamiento del sensor con respecto a la piel (M_{mec}), lo cual produce un cambio en el ángulo de incidencia y la trayectoria de la luz, y que correspondería con el término d de la ecuación. Por otra parte, la deformación interna y el cambio estructural de ciertos tejidos debido al movimiento de los dedos ($M_{vascular}$), lo cual produce un artefacto en la señal, y que correspondería con el término c . En la Figura 8.3 se muestra un modelo simplificado de lo anteriormente expuesto, donde vemos que los artefactos de movimiento totales son la suma de los artefactos provocados por el desplazamiento del sensor y los artefactos provocados por los cambios en el tejido micro vascular debido al movimiento de los dedos.

En el caso de los dispositivos de monitorización donde la medida de la señal de **PPG** se realiza sobre la muñeca, el acelerómetro que también se encuentra sobre la muñeca es capaz de registrar los artefactos del movimiento del brazo (M_{mec}), pero no puede registrar los artefactos procedentes del movimiento de los dedos ($M_{vascular}$). Por tanto, el problema de las soluciones que eliminan los artefactos de movimiento a partir del

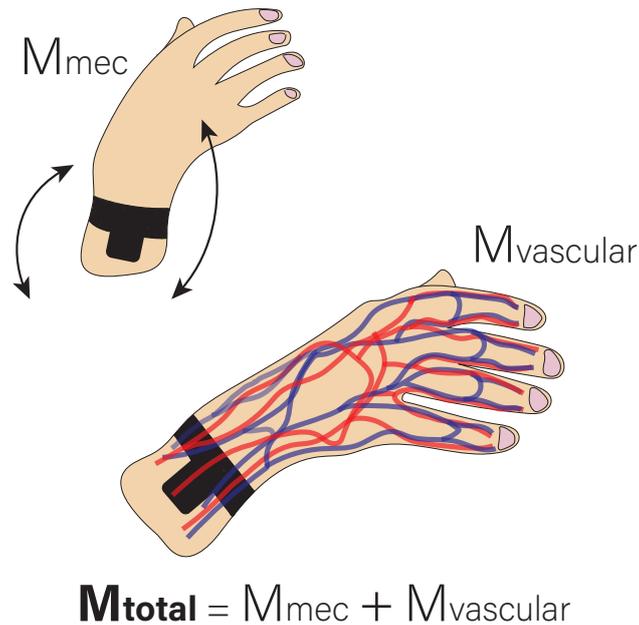


Figura 8.3: Modelo simplificado de los artefactos de movimiento en la señal de PPG.

espectro en frecuencia de las señales de aceleración es que no son capaces de eliminar la componente del cambio de tejidos provocados por el movimiento de los dedos e incluso algunos movimientos de la muñeca.

Pese a ello, se ha tratado de implementar estos métodos con las señales obtenidas por el dispositivo de monitorización para estudiar los resultados conseguidos. En la Figura 8.4, se muestra una gráfica de la señal de la FC reconstruida aplicando un filtro adaptativo a partir de las señales de aceleración y un filtro *notch* para substraer las frecuencias asociadas a artefactos de movimiento. Se puede observar como a pesar de eliminar los artefactos de movimiento procedentes del movimiento del brazo siguen apareciendo picos de valor incorrecto durante el desarrollo de una misma tarea donde se mantiene estable el valor de FC del usuario. En la parte final de la gráfica, manteniendo el brazo y la mano del usuario en reposo, la señal no presenta esos picos procedentes de los artefactos de movimiento. Por todo ello, las soluciones disponibles de la literatura no arrojan una solución al problema presentado y será necesario desarrollar algún procedimiento a partir de las diferentes propuestas analizadas.

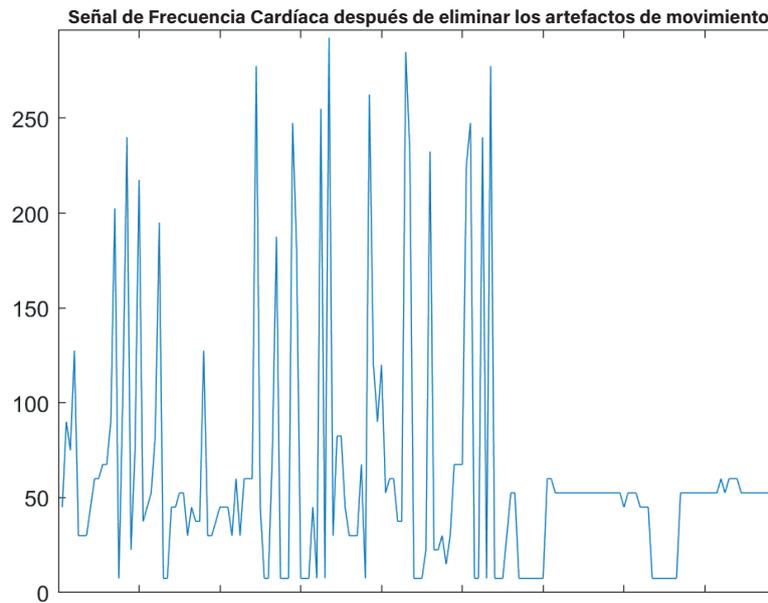


Figura 8.4: Señal de la FC reconstruida aplicando una solución de filtro adaptativo a partir de las señales de aceleración.

8.2 ALGORITMO DE RECONSTRUCCIÓN DE LA FRECUENCIA CARDÍACA MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMATIZADO

En esta sección se presenta una propuesta para solventar el problema de los artefactos de movimiento anteriormente estudiado. Debido a que no se han encontrado soluciones existentes que se adapten a los requerimientos de la plataforma y al dispositivo desarrollado, se ha optado por desarrollar un método propio mediante el cual reconstruir la señal de la FC.

El algoritmo plantea el uso de todas las señales disponibles en el dispositivo de monitorización personal (temperatura corporal, aceleración, giroscopio y PPG) y se divide en dos partes principales. En primer lugar, a partir de las señales disponibles generar y seleccionar los atributos adecuados para entrenar un modelo de clasificación que se encargue de detectar cuándo el usuario está llevando a cabo tareas en las que implica movimiento de los brazos y/o de los dedos. Se decide no utilizar las señales de aceleración directamente con unos límites para determinar los instantes en los que existe movimiento al contrario que en algunas de las soluciones analizadas de la literatura, como por ejemplo (Lee et al., 2020), dado que la señal del acelerómetro únicamente capta los movimientos del brazo y no los de los dedos. Para la segunda parte, se

seleccionan nuevamente los atributos adecuados pero en este caso para entrenar un modelo de regresión que sea capaz de estimar la FC. Este segundo modelo se utilizará para calcular la FC en aquellos instantes en los que el modelo de clasificación determine que el usuario desarrolla una tarea donde existe movimiento.

Para poder entrenar estos modelos predictivos es necesario disponer de un dataset lo suficientemente grande y de calidad para que el comportamiento de los modelos sea óptimo y se puedan obtener unos resultados lo suficientemente precisos como para incorporar el trabajo en la plataforma. Para ello, se ha realizado una experimentación donde diferentes usuarios han llevado a cabo unas determinadas tareas mientras llevaban consigo el dispositivo de monitorización personal presentado en esta tesis y a su vez también tienen instalado el dispositivo "Zephyr BioHarness" de Medtronic (Medtronic, 2021). Este dispositivo consiste en una banda pectoral y proporciona la señal de la FC del usuario a partir de la medida de ECG. Además, proporciona el valor de confianza de la señal de FC para cada instante, por lo tanto, se puede utilizar la señal proporcionada por este dispositivo como señal de alta precisión para el entrenamiento del modelo de regresión y trabajar con aprendizaje supervisado.

8.2.1 Protocolo para la adquisición de señales con usuarios

Para la adquisición de las señales se ha seguido la idea presentada en el diagrama de la Figura 8.5. El usuario se coloca el dispositivo de monitorización de señales fisiológicas en su mano dominante y el dispositivo *BioHarness* correctamente ajustado en el torso. De la pulsera de monitorización se obtienen las cuatro variables disponibles (PPG, acelerómetro, giroscopio y temperatura corporal), a partir de las cuales se generarán los atributos que compondrán las entradas del dataset. Del *BioHarness* se obtiene la señal de ECG a partir de la cual se extrae la señal de FC, y también se utiliza la señal del acelerómetro del dispositivo *BioHarness* para realizar una sincronización de los datos de ambos dispositivos durante el procesamiento de las señales y la construcción del conjunto de datos. Finalmente, el dataset quedará compuesto por los atributos generados a partir de las señales de la pulsera y dos parámetros extra, uno con el etiquetado de la tarea real que está desarrollando el usuario en cada instante, que se utilizará como salida en el entrenamiento del modelo de clasificación, y otro con el valor de FC del *BioHarness*, que se utilizará como etiqueta para el entrenamiento del modelo de regresión. A partir de este dataset se entrenarán los respectivos modelos.

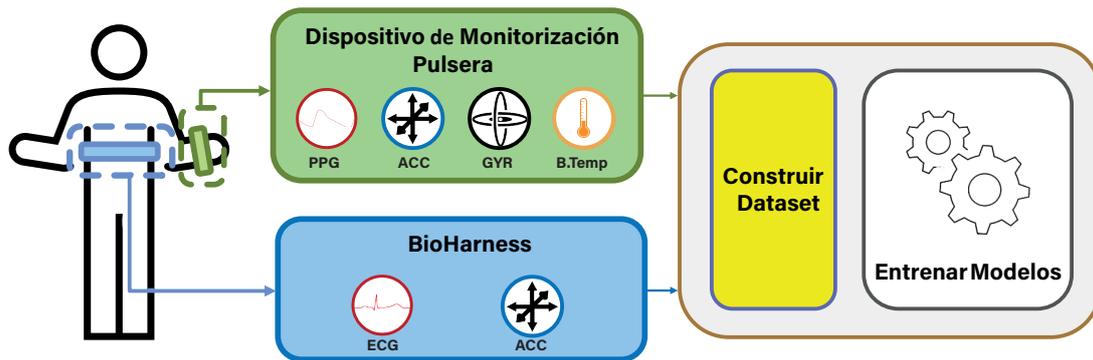


Figura 8.5: Diagrama de trabajo para el registro de datos utilizando el *BioHarness* en paralelo al dispositivo de monitorización de señales fisiológicas.

Para la adquisición de datos se ha diseñado un protocolo de 9 actividades con un tiempo de duración total de aproximadamente 30 minutos, donde han participado 10 usuarios sanos diferentes (5 mujeres y 5 hombres) con una edad media de 27,2 años y una desviación estándar de 1,99 años. En la Tabla 8.1 se muestra el listado completo de actividades y en la Figura 8.6 se puede observar una fotografía de usuarios llevando a cabo las diferentes actividades. Éstas han sido clasificadas en 3 grupos distintos dependiendo del tipo de movimiento y la intensidad de los movimientos del usuario. El grupo de actividades de color rojo se corresponde con "actividades de reposo", donde el usuario se mantiene sentado en una silla y relajado, con la mano en una posición fija y tratando de no realizar movimientos. El grupo de color verde se corresponde con actividades donde el usuario se mantiene sentado en la silla pero realiza movimientos de brazo leves y con los dedos más intensamente. En la tarea B el usuario simula la lectura de un libro pasando las páginas de éste con la mano dominante de manera periódica (aproximadamente una página cada 5 segundos), mientras que en la tarea C el usuario escribe o dibuja sobre papel de manera natural. El último grupo, de color azul, se corresponde con actividades donde el usuario se desplaza caminando con los movimientos naturales del brazo al andar. En la tarea D el usuario debe caminar a un ritmo lento, mientras que en el desarrollo de la tarea E debe incrementar el ritmo de caminar para que incremente la FC.

Como resultado de las experimentaciones se obtiene un conjunto de datos formado por 16192 entradas. Cada una de ellas formada por 63 atributos generados a partir de las 4 señales fisiológicas disponibles en la pulsera de monitorización. Los atributos son los ya presentados en la Sección 6.1.1, en su mayoría parámetros estadísticos junto con las derivadas primera y segunda y el cálculo de la energía de la respuesta en

Actividad	Tiempo (min)
Baseline (A)	5
Leer (B)	3
Pausa (A)	2
Caminar despacio (D)	5
Pausa (A)	2
Escribir / Dibujar (C)	3
Pausa (A)	2
Caminar deprisa (E)	5
Pausa (A)	2
TOTAL	~30

Tabla 8.1: Lista de las actividades desarrolladas durante el registro de datos.

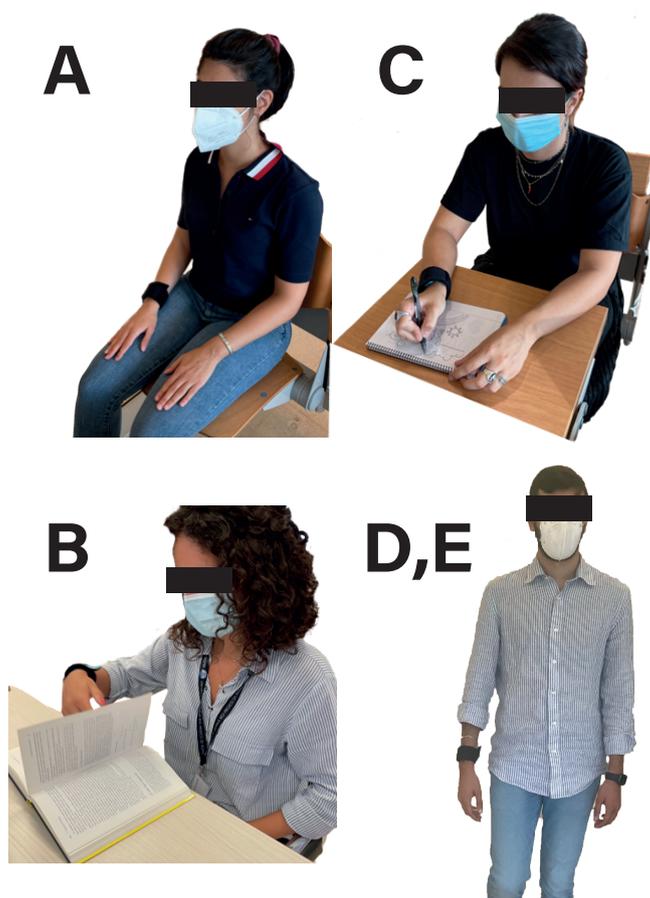


Figura 8.6: Fotografías de usuarios realizando las diferentes actividades propuestas para el registro de datos.

frecuencia y la frecuencia dominante. Además el dataset incorpora la etiqueta de la FC del *BioHarness* y la etiqueta de la tarea real con 3 clases diferentes posibles, una por cada grupo de actividades. Por lo tanto el conjunto de datos disponible tiene unas dimensiones de 16192 entradas y 65 atributos.

Por último, faltaría realizar la normalización del conjunto de datos, mezclar las entradas de manera aleatoria y dividirlo en dos dataset diferentes, uno para entrenamiento y otro para evaluación de los modelos. Para ello se aplica la norma de un 70 % de los datos para el conjunto de entrenamiento y el 30 % restante reservado para la evaluación.

8.2.2 Entrenamiento de un modelo de clasificación de actividades

El primero de los modelos que se tiene que entrenar para usar en el algoritmo presentado es el modelo que clasifica entre los tres grupos de tareas diferentes. Para el entrenamiento, al grupo de tareas en reposo se le ha asignado la clase 1, al grupo de tareas con movimientos específicos de los dedos la clase 2 y el grupo de tareas con desplazamiento del usuario la clase 3. Además, para la validación de los modelos durante el entrenamiento se ha utilizado la validación cruzada "*k-fold*" con una *k* igual a 5.

Antes de comenzar el entrenamiento, se aplica un algoritmo de reducción de la dimensionalidad para establecer cuáles son los atributos más importantes en el conjunto de datos para el objetivo del modelo. El algoritmo utilizado es el Análisis de Componentes de Vecindario o *Neighborhood Component Analysis (NCA)*, un método específico para problemas de clasificación. El *NCA* va un paso más allá del *PCA* y agrupa los atributos basándose en los resultados de la reducción de la dimensionalidad. Para ello utiliza la varianza de los componentes para estimar el número de clústeres, algo parecido a lo que realiza el algoritmo de *k-means*. En la Figura 8.7 se muestra el resultado de aplicar el algoritmo al conjunto de datos de entrenamiento. Se puede observar el peso de los diferentes atributos según la importancia para clasificar la actividad. Se han seleccionado aquellos atributos con un peso devuelto por el algoritmo superior a 0.5. Esto corresponde con 9 atributos que se ven resaltados en la gráfica en color verde y que se listan junto con el índice de atributo que les corresponde.

Una vez aplicado el algoritmo de reducción de la dimensionalidad se pasa a realizar el entrenamiento del modelo aplicando diferentes algoritmos. Para realizar el

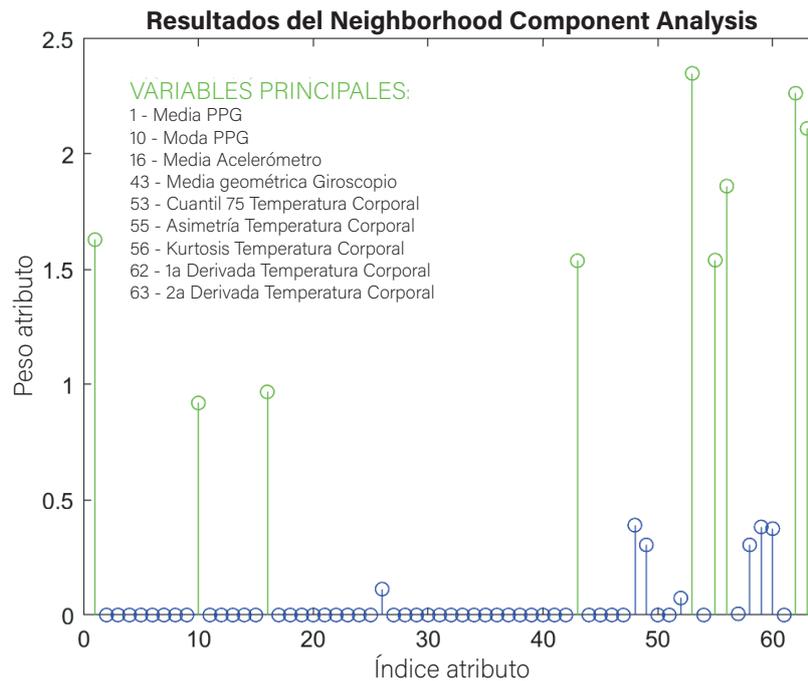


Figura 8.7: Resultado de aplicar el algoritmo NCA a los atributos del conjunto de datos con los pesos de cada atributo.

entrenamiento del modelo de clasificación se ha utilizado la herramienta *Classification Learner* de *Matlab*[®]. En la Tabla 8.2 se muestra el resultado del entrenamiento para diferentes algoritmos y comparando la exactitud del modelo entrenado con los 9 atributos seleccionados más importantes según el NCA con el modelo entrenado con los 63 atributos originales del conjunto de datos. Se observa que en general los modelos generados con todos los algoritmos tienen un mejor rendimiento cuando se utiliza únicamente los 9 atributos más destacados que empleando el conjunto completo. Además, los algoritmos convergen en menor tiempo y son modelos más optimizados, ligeros y rápidos para implementar inferencia en tiempo real. Entre todos los modelos se ha seleccionado el generado con el algoritmo de Agregación de árboles de decisión, el cual tiene una exactitud mayor (96,9 %) seguido del modelo de KNN (96,1 %), pero que además éste es más lento que el modelo seleccionado.

Para el modelo seleccionado, se ha aplicado la optimización bayesiana para obtener los valores de hiperparámetros óptimos para el modelo. Como resultado de esta optimización, el modelo final para la clasificación de tareas tiene las siguientes características:

Algoritmo	Exactitud (9 atributos)	Exactitud (63 atributos)
Árbol de decisión	94,3 %	92,9 %
KNN	96,1 %	96,2 %
SVM	91,3 %	73,0 %
Agregación de árboles	96,9 %	96,5 %
Naive Bayes	76,8 %	74,1 %

Tabla 8.2: Resultados del entrenamiento de modelos para la clasificación de la tarea en desarrollo.

Algoritmo = Agregación de árboles de decisión

Método de agregación = AdaBoost

Número de aprendices = 492

Tasa de aprendizaje = 0,34449

Número máximo de ramificaciones = 204

Velocidad de predicción = ~ 5800/s

Tiempo de entrenamiento = 104,54s

En la Figura 8.8 se muestra además la matriz de confusión resultado de la evaluación del modelo con el conjunto de datos reservado para tal fin. Se puede ver como el modelo presenta una exactitud del 96,8 % de manera global realizando predicciones de tareas frente a los datos nuevos. Para el grupo de tareas con desplazamiento del usuario este porcentaje incluso se incrementa por encima del 98 %, ya que el modelo identifica más claramente este tipo de situaciones. Las pocas confusiones que se producen son principalmente entre las actividades de reposo y las de movimientos específicos de los dedos, ya que el usuario mantiene unas condiciones similares en ambas tareas. Sin embargo, es un valor residual ya que solo alcanza el 1 % de los valores pronosticados.

Matriz de confusión

Clase de salida	1	2098 42.9%	48 1.0%	29 0.6%	96.5% 3.5%
	2	48 1.0%	1084 22.2%	2 0.0%	95.6% 4.4%
	3	23 0.5%	4 0.1%	1551 31.7%	98.3% 1.7%
		96.7% 3.3%	95.4% 4.6%	98.0% 2.0%	96.8% 3.2%
	1	2	3		Clase real

Figura 8.8: Matriz de confusión resultado de la evaluación del modelo de clasificación final.

8.2.3 Entrenamiento de un modelo de estimación de la frecuencia cardíaca

El segundo modelo que forma el algoritmo propuesto consiste en un modelo de regresión que estime el valor de la FC. Para el entrenamiento de este modelo se utiliza como etiqueta de salida el valor de la FC medida por el *BioHarness*. Al igual que en el entrenamiento del modelo de clasificación, para la validación de los modelos durante el entrenamiento se ha utilizado la validación cruzada "5-fold".

Antes del entrenamiento, se aplica nuevamente un algoritmo de reducción de la dimensionalidad para establecer cuáles son los atributos más importantes del conjunto para el nuevo objetivo. En este caso se ha utilizado el algoritmo *ReliefF* (Kira y Rendell, 1992). Este algoritmo penaliza a los predictores que asignan valores diferentes a sus vecinos con el mismo valor de respuesta y premia a aquellos predictores que asignan valores diferentes a los vecinos con valores de respuesta diferentes. En la Figura 8.9 se muestra el resultado de aplicar el algoritmo al conjunto de datos de entrenamiento. Se puede observar el peso de los diferentes atributos según la importancia asignada por el algoritmo *ReliefF* para la estimación de la FC. Al igual que en el modelo de clasificación, se han seleccionado aquellos atributos con un peso superior a 0.008. En este caso el

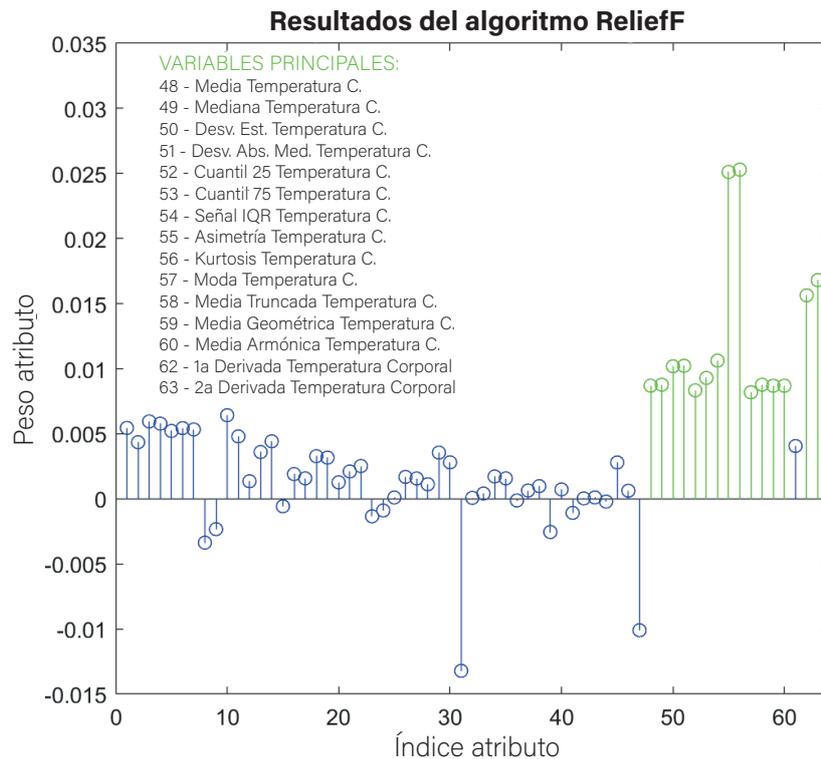


Figura 8.9: Resultado de aplicar el algoritmo ReliefF a los atributos del conjunto de datos con los pesos de cada atributo.

algoritmo devuelve una escala diferente al utilizado en el modelo de clasificación. Este umbral corresponde con 15 atributos diferentes, los cuales se ven resaltados en la gráfica en color verde y además se listan junto con el índice de atributo correspondiente. Se puede observar como los 15 atributos seleccionados corresponden con la variable de la temperatura corporal. Esto parece lógico ya que para la estimación de la *FC* en situaciones en las que la señal de *PPG* está corrupta, ésta no aporta información valiosa al modelo. Lo mismo ocurre con las señales de aceleración y del giroscopio, son señales que si aportan información para predecir la tarea que realiza el usuario pero no así para estimar cual es el valor de la *FC*.

Una vez aplicado el algoritmo de reducción de la dimensionalidad se pasa a realizar el entrenamiento del modelo utilizando diferentes algoritmos para comparar los resultados de los modelos generados por cada uno. Para realizar el entrenamiento del modelo de regresión se ha utilizado la herramienta *Regression Learner* de *Matlab*[®]. En la Tabla 8.3 se muestra el resultado del entrenamiento para diferentes algoritmos y comparando la raíz del error cuadrático medio de los modelos entrenados con los 15

Algoritmo	RMSE (PPM) (15 atributos)	RMSE (PPM) (22 atributos)
Árbol de decisión	5,08	6,93
Regresión en Procesos Gaussianos	5,07	9,68
SVM	6,89	12,47
Agregación de árboles	4,95	5,44
Regresión Lineal	16,4	18,43

Tabla 8.3: Resultados del entrenamiento de modelos para la estimación de la frecuencia cardíaca.

atributos seleccionadas más importantes según el algoritmo *ReliefF* para un umbral por encima de 0.008, con los modelos entrenados utilizando los atributos más importantes si le bajásemos el umbral hasta un valor de 0.005 (22 atributos seleccionados). Se observa como añadir más atributos a los modelos no sólo no mejora los resultados del entrenamiento, sino que además volverá más lentos los modelos dificultando la integración en tiempo real del sistema. Por lo tanto, se justifica el uso del umbral de 0.008 y la elección de los 15 atributos más destacados. Por otra parte, tenemos la comparativa de resultados entre los diferentes modelos. Entre todos ellos se han seleccionado en este caso dos, el generado con el algoritmo de Regresión en Procesos Gaussianos, con un RMSE de 5,07 PPM y cuyo comportamiento en rangos donde la FC es más baja es mejor, y el generado con el algoritmo de Agregación de árboles de decisión, con un RMSE de 4,95 PPM y cuyo comportamiento en rangos donde la FC es más alta es mejor.

Para los modelos seleccionados, se ha aplicado la optimización bayesiana para obtener el valor óptimo de los hiperparámetros para ambos modelos, al igual que se hizo para el modelo de clasificación. Como resultado de los procesos de optimización, se presentan las características de ambos modelos finales:

■ Modelo de Regresión en Procesos Gaussianos

Función base = Constant

Función del núcleo = IsotropicExponential

Escala del núcleo = 0,55637

Estandarizar = Activado

Desviación de la estandarización de la seal = 14,331

Sigma = 69,2202

Velocidad de predicción = ~ 5300/s

Tiempo de entrenamiento = 181,5s

■ Modelo de Agregación de árboles de decisión

Algoritmo = Agregación de árboles de decisión

Método de agregación = Bag

Número de aprendices = 14

Tamaño mínimo de hojas = 3

Velocidad de predicción = ~ 240000/s

Tiempo de entrenamiento = 1,26s

Como resultado de la evaluación de los modelos con el conjunto de datos para test se ha obtenido un RMSE total de 5,02 PPM para el modelo de Regresión en Procesos Gaussianos. Respecto de los RMSE parciales, las entradas pertenecientes al grupo de tareas 1, actividades de reposo, este modelo tiene un RMSE de 5,42 PPM. Para el grupo de tareas 2, actividades con movimientos específicos de los dedos, el modelo tiene un RMSE de 4,48 PPM. Y para el grupo de tareas 3, actividades con desplazamiento del usuario, un RMSE de 4,84 PPM. En cuanto al modelo de Agregación de árboles de decisión, ha obtenido un RMSE total de 4,89 PPM, mientras que para los tres diferentes grupos de tareas ha obtenido un RSME de 5,20, 4,86 y 4,30 PPM, respectivamente.

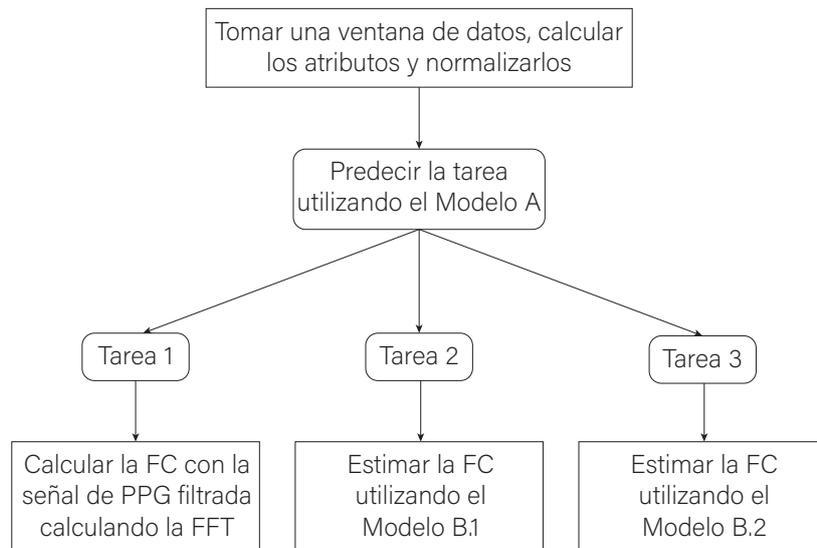


Figura 8.10: Representación gráfica de los procesos del algoritmo implementado.

8.2.4 Arquitectura del algoritmo implementado

Una vez finalizado el entrenamiento de los modelos y evaluado su comportamiento con el conjunto de datos de test, se presenta la estructura de funcionamiento del algoritmo. En la Figura 8.10 se muestra un esquema conceptual donde se puede ver el flujo de funcionamiento del algoritmo.

En primer lugar, se captura una ventana de las diferentes señales de la pulsera de monitorización. A partir de esa ventana de datos de las señales se calculan los atributos, únicamente aquellos que se han utilizado finalmente para el entrenamiento de los modelos pertenecientes al algoritmo, un total de 19 atributos. Y a continuación, se normalizan esos atributos con el rango de valores obtenido de la normalización llevada a cabo con el dataset de entrenamiento, de modo que los nuevos valores introducidos al modelo mantengan una relación con aquellos con los que fue entrenado éste. Tras obtener los atributos de entrada normalizados, se utiliza el modelo de clasificación de tareas (**Modelo A**) para establecer qué actividad está realizando el usuario en ese instante, y en base a la tarea, estimar la FC de una manera diferente.

En función de la tareas que esté llevando a cabo el usuario, existen tres caminos diferentes para calcular la FC de éste. Por un lado, si como resultado del modelo de clasificación obtenemos que el usuario está desarrollando una tarea del grupo 1, es decir,

está en reposo, el cálculo de la FC se realiza aplicando el filtrado original presentado en la Sección 3.2.2 y mediante la FFT de la señal de PPG.

Sin embargo, si el resultado del modelo de clasificación es que el usuario está realizando una tarea de los grupos 2 o 3, el cálculo de la FC se realizará empleando uno de los modelos de regresión previamente entrenados. En caso de que la tarea pertenezca al grupo 2, el modelo utilizado será el **Modelo B.1**, que corresponde con el modelo generado con el algoritmo de Regresión en Procesos Gaussianos, el cual tiene un mejor rendimiento en la estimación para actividades con unos rangos de valores de FC más bajos. Finalmente, cuando la tarea predicha corresponda al grupo 3, se utilizará el **Modelo B.2**, que corresponde con el modelo generado con el algoritmo de Agregación de árboles de decisión, que tiene un mejor comportamiento en actividades donde los valores de FC son más altos.

8.3 RESULTADOS DE LA RECONSTRUCCIÓN DE LA FRECUENCIA CARDÍACA UTILIZANDO EL ALGORITMO DESARROLLADO

En esta sección se presentan los resultados de aplicar el algoritmo desarrollado en la reconstrucción de la señal de la FC de diferentes usuarios. Para ello se han capturado 4 nuevas sesiones con 4 usuarios diferentes, siguiendo el mismo protocolo que en la experimentación para la adquisición de los registros utilizados en el entrenamiento de los modelos.

El primero de los usuarios ha participado previamente en la experimentación para el entrenamiento de los modelos. Además, se trata de un usuario cuya confianza en la señal de FC del *BioHarness* durante la sesión ha sido muy alta, con una media del 95%. El resultado de la reconstrucción se muestra en la Figura 8.11. Los valores de la gráfica pintados en rojo corresponden con los calculados por el método designado para la tarea 1, es decir, utilizando la señal de PPG filtrada y calculando la FFT de ésta. Aquellos pintados en verde corresponden con los calculados con el modelo designado para la tarea 2, es decir, utilizando el **Modelo B.1**. Por último, los puntos coloreados en azul se corresponden con los valores calculados con el modelo designado para la tarea 3, es decir, el **Modelo B.2**. Además, la señal pintada de negro se corresponde con la señal de FC medida por el *BioHarness*. Se observa como la señal reconstruida sigue a la forma de la señal medida por el *BioHarness* a lo largo de toda la sesión, aunque se aprecian diferencias importantes en algunos puntos.

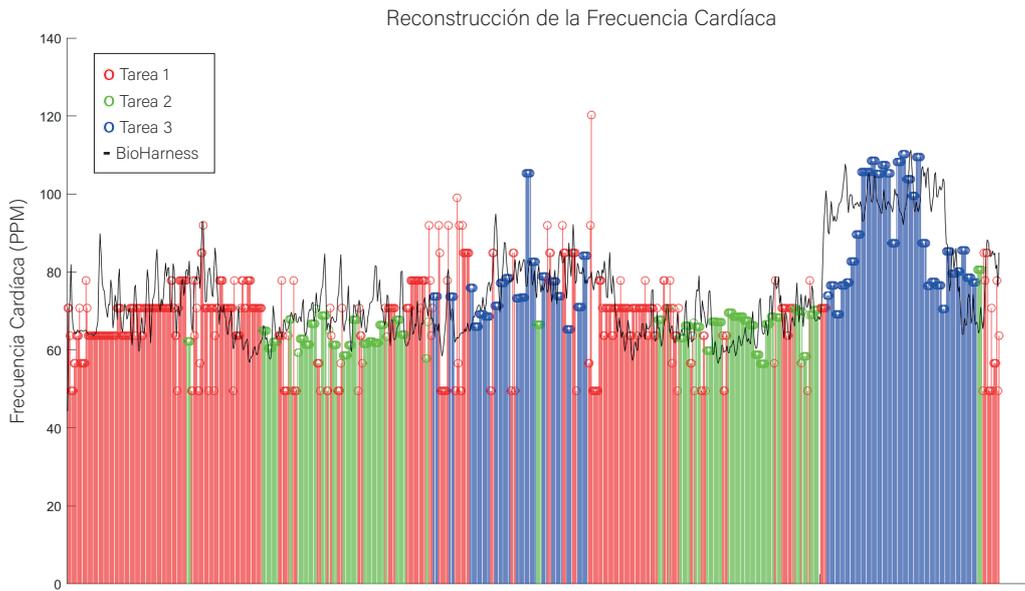


Figura 8.11: Resultado de la reconstrucción de la FC en un usuario participante en el entrenamiento y con alta confianza en la FC del *BioHarness*.

Para evaluar el comportamiento del algoritmo se presentan los resultados en la Tabla 8.4. Por un lado, el algoritmo está identificando correctamente la tarea que realmente se está desarrollando con un 83,3 % de éxito. En la tarea 3, el algoritmo la ha identificado correctamente casi todas las veces, con una precisión del 98 % y una sensibilidad del 85 %. Mientras, para las tareas 2 y 3 los valores disminuyen cercanos al 80 %, lo que indica que estos dos grupos de tareas el algoritmo los confunde entre sí en algunas ocasiones, debido presumiblemente a que la intensidad de las actividades no dista mucho una de otra.

Respecto a los resultados de la FC calculada, se presentan los RMSE tanto globales como de cada una de las tareas siempre comparando los valores calculados con el algoritmo y los valores de la señal de FC del *BioHarness*. El $RMSE_{global}$ es de 12,20 PPM, mientras que el error para la tarea 2, con los movimientos específicos de los dedos, desciende por debajo de 8 PPM.

El segundo usuario también es un participante de la adquisición de datos para el entrenamiento de los modelos. Sin embargo, en esta ocasión la confianza de la señal de FC del *BioHarness* durante la sesión ha sido muy baja, con una media del 53 %, lo que indica que la señal medida con este dispositivo no es fiable en esta sesión. El resultado de la reconstrucción junto con la señal de FC del *BioHarness* se muestra en la Figura

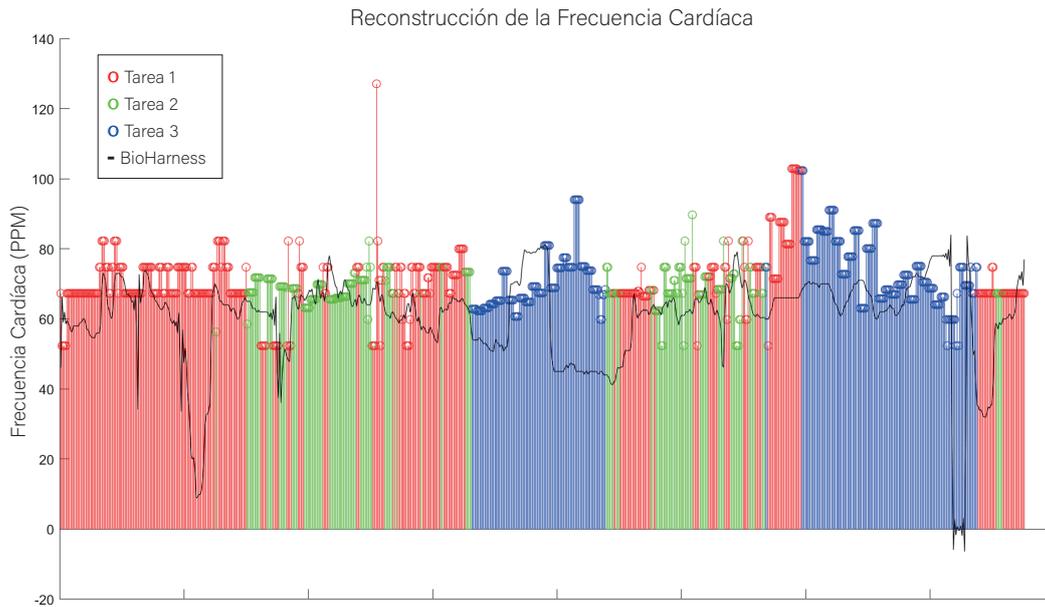


Figura 8.12: Resultado de la reconstrucción de la FC en un usuario participante en el entrenamiento y con baja confianza en la FC del *BioHarness*.

8.12. Se puede ver como la señal medida por el *BioHarness* está dañada, con cambios bruscos en la forma y valores irreales. Sin embargo, si se analiza la señal reconstruida, se ve como se mantiene estable a nivel general, con una forma más reconocible y con el aumento de la señal en las actividades donde hay una mayor intensidad.

En la Tabla 8.5 se presentan los resultados del algoritmo para este usuario. El algoritmo ha clasificado correctamente la tarea que realizaba el usuario con una exactitud del 88,2 %, llegando casi al 100 % cuando se trataba de la tarea 3. Respecto a las tareas 1 y 2 se mantiene en valores similares respecto al primer usuario, mejorando incluso un poco los resultados. En cuanto a los resultados de la FC dado que la comparativa se realiza con los valores proporcionados por la señal del *BioHarness*, no son muy significativos para este usuario ya que la señal está dañada. Sin embargo, para la tarea 2 donde el error en la señal del *BioHarness* parece disminuir, el $RMSE_2$ es de un 9,60 PPM.

El siguiente usuario es un nuevo participante que no formó parte en el registro de datos para el entrenamiento de los modelos. Además, se trata de un usuario con un rango de valores en la FC anormalmente bajos, en torno a 45 PPM en reposo y con un incremento lento al intensificar la actividad física. Respecto a la confianza en la señal de FC del *BioHarness*, la media es del 79 %. En la Figura 8.13 se muestra el resultado de la

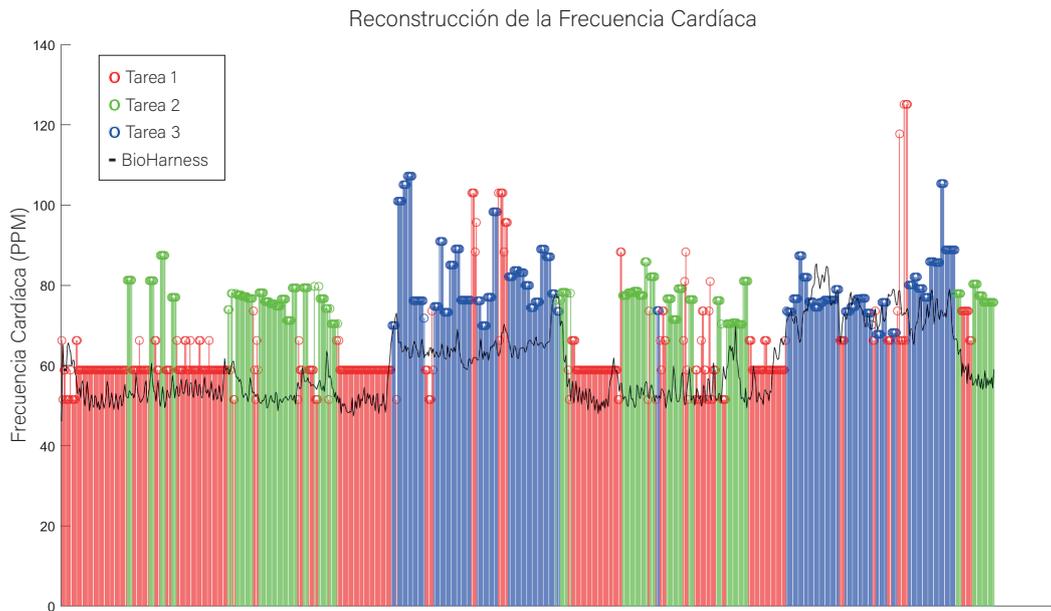


Figura 8.13: Resultado de la reconstrucción de la FC en un nuevo usuario con el rango de valores de la FC anormalmente bajos.

reconstrucción también con la señal de FC del *BioHarness*. Se puede ver como la señal reconstruida sigue en todo momento la forma de la señal del *BioHarness*, sin embargo, los valores estimados por el algoritmo son en todo momento mayores a los de la señal del *BioHarness*, excepto para la actividad de mayor intensidad física donde los valores de FC del usuario se incrementan hasta valores más típicos. El motivo de este suceso es que el modelo ha sido entrenado con 10 usuarios los cuales tenían un rango de valores para la FC típicos y el modelo ha aprendido de ellos durante el entrenamiento. Por lo tanto, aplicar el modelo a un usuario nuevo con unos rangos atípicos arroja unos resultados poco precisos aunque ya esperados.

No obstante, en la Tabla 8.6 se presentan los resultados del algoritmo para este usuario. La clasificación de la tarea se ha realizado con un 80 % de éxito, nuevamente con unos valores casi perfectos cuando se trata de la tarea 3. Respecto a los resultados de la FC no son significativos ya que se conocía previamente que al ser un usuario nuevo fuera del rango de valores del conjunto de datos para el entrenamiento no iban a ser demasiado acertados. Sin embargo, para la tarea 1 que se realiza utilizando la señal de PPG filtrada, el $RMSE_1$ es de 12,08 PPM, similares al resto de usuarios ya que no depende del entrenamiento de los modelos.

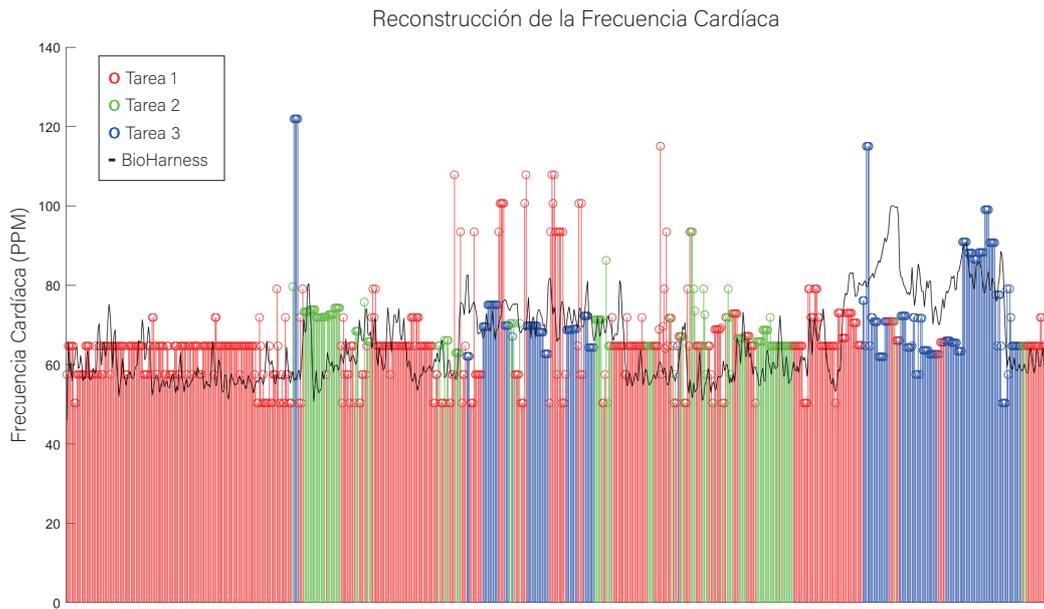


Figura 8.14: Resultado de la reconstrucción de la FC en un nuevo usuario con el rango de valores de la FC típico.

El último de los usuarios utilizados para la evaluación del algoritmo es también un nuevo participante que no contribuyó en el entrenamiento de los modelos. En esta ocasión se trata de un usuario con un rango de valores en la FC típico y con una media en la confianza de la señal de la FC del *BioHarness* del 85%. El resultado de la reconstrucción junto con la señal de FC del *BioHarness* de esta sesión se muestra en la Figura 8.14. Se observa como la señal reconstruida sigue en todo momento la forma de la señal del *BioHarness* y en este caso con unos valores similares entre ambas. Destaca en la última actividad de la tarea 3, que si aparece una diferencia en el rango de valores donde la señal reconstruida comienza la tarea con unos valores por debajo de los medidos por el *BioHarness*. Esto es debido a que el modelo de predicción utiliza los atributos provenientes de la temperatura corporal y ésta es más lenta que la señal de la FC en el usuario.

Los resultados del algoritmo para esta sesión se muestran en la Tabla 8.7. La clasificación de la tarea se ha realizado con éxito en un 80,6% de las ocasiones, muy similar al resto de las sesiones, siendo nuevamente la tarea 3 la mejor identificada. Con respecto al resultado de la FC calculada, el $RMSE_{total}$ de la sesión es de 13,03 PPM, incrementándose para la tarea 3 debido al motivo previamente analizado.

Clasificación de tarea				Cálculo FC	
Tarea	Precision	Recall	F1-score	Tarea	RMSE (PPM)
1	0,79	0,86	0,83	1	13,06
2	0,75	0,76	0,76	2	7,95
3	0,98	0,85	0,91	3	13,82
Accuracy			83,3%	Total	12,20

Tabla 8.4: Tabla de resultados de la sesión de un usuario con la cofianza de la señal de la FC del *BioHarness* alta.

Clasificación de tarea				Estimación FC	
Tarea	Precision	Recall	F1-score	Tarea	RMSE (PPM)
1	0,86	0,90	0,88	1	21,14
2	0,77	0,69	0,73	2	9,60
3	0,99	1,00	1,00	3	17,72
Accuracy			88,2%	Total	18,36

Tabla 8.5: Tabla de resultados de la sesión de un usuario con la cofianza de la señal de la FC del *BioHarness* baja.

Clasificación de tarea				Estimación FC	
Tarea	Precision	Recall	F1-score	Tarea	RMSE (PPM)
1	0,71	0,86	0,78	1	12,08
2	0,73	0,70	0,71	2	22,91
3	0,98	0,81	0,89	3	16,49
Accuracy			80,0%	Total	16,64

Tabla 8.6: Tabla de resultados de la sesión de un usuario nuevo con el rango de valores de la FC anormalmente bajos.

Clasificación de tarea				Estimación FC	
Tarea	Precision	Recall	F1-score	Tarea	RMSE (PPM)
1	0,76	0,96	0,85	1	13,22
2	0,72	0,58	0,64	2	10,80
3	0,97	0,67	0,79	3	15,17
Accuracy			80,6%	Total	13,03

Tabla 8.7: Tabla de resultados de la sesión de un usuario nuevo con el rango de valores de la FC típico.

Como se ha podido comprobar en los resultados, el algoritmo permite reconstruir la señal de la **FC** del usuario cuando éste está desarrollando tareas con movimientos de los dedos o desplazamientos y la señal de **PPG** se corrompe. A partir de los resultados presentados se puede extraer además que si el modelo es entrenado con información del usuario con el que se va a utilizar el algoritmo, el error se puede reducir ya que el modelo aprenderá información acerca del comportamiento del usuario. Esto es especialmente importante si el rango de valores de la **FC** del usuario es atípico. Este hecho puede plantear un contratiempo al trasladar el uso del algoritmo a personas con **TEA**, ya que posiblemente no se pueda entrenar el modelo con información del propio usuario, proporcionada por un dispositivo como es el *BioHarness* debido a que no suelen tolerar ese tipo de sistemas, "*invasivos*" para ellos. Sin embargo, se pueden plantear soluciones para corregir esto. Por ejemplo, se puede obtener información del usuario a partir de las señales de la propia pulsera de monitorización analizándolas detalladamente para extraer los datos válidos donde la señal de **PPG** no esté corrupta. Además, a partir de esa información se podría trabajar con una red generativa antagónica para generar datos sintéticos a partir de los disponibles y aumentar así el tamaño del dataset para entrenar el modelo. En cualquier caso, utilizar el algoritmo presentado aún sin poder entrenarlo con información particular del usuario en concreto, permitirá reconstruir la señal de la **FC** en aquellas sesiones o partes de éstas donde por algún motivo, como puede ser por ejemplo que ese día no tolerase una fijación correcta del dispositivo o debido a una alta intensidad en las actividades desarrolladas, la señal de **PPG** se corrompa.

8.4 CONCLUSIONES DEL CAPÍTULO

En este capítulo se ha presentado un algoritmo que permite calcular la **FC** del usuario a partir de las señales disponibles en el dispositivo de monitorización personal desarrollado cuando la señal de **PPG** se corrompe debido a que el usuario está llevando a cabo alguna tarea que implica el movimiento del brazo, de la muñeca o de los dedos. Tras analizar las soluciones existentes en la literatura y comprobar que no se ajustaban a los requerimientos de la plataforma, se propone un método para estimar la frecuencia cardíaca utilizando modelos de **AA**.

Para entrenar los modelos predictivos se ha realizado una experimentación a fin de recolectar la mayor información posible. Con el conjunto de datos obtenido se han calculado y seleccionado una serie de atributos que han permitido entrenar los modelos

para implementar el algoritmo. Finalmente, se ha utilizado el algoritmo desarrollado para reconstruir la señal de FC de cuatro usuario con condiciones diferentes y se han analizado los resultados tanto de la reconstrucción como del comportamiento del algoritmo.

CONCLUSIONES

9.1 CONCLUSIÓN

Las personas que sufren un **TEA** suelen tener asociado un **TPS** que les hace sentir los estímulos del entorno de una manera diferente al resto de personas. Además, esas características especiales dependen de cada persona que lo padece y de la situación en la que se encuentre en cada momento. Esto provoca que en algunas ocasiones estas personas se puedan sentir abrumadas por los estímulos presentes en su entorno, haciéndolos salir de su zona de confort y pudiendo incluso derivar en una crisis de conducta, sobretodo en aquellos más pequeños o con una discapacidad intelectual asociada.

Para tratar de controlar esas circunstancias, se ha desarrollado una plataforma para tratar de identificar las situaciones donde las personas con **TEA** se ven afectadas por los estímulos del entorno. Esa plataforma está compuesta por cuatro dispositivos de monitorización que se encargan de medir los estímulos del entorno presentes en cada momento, y a su vez medir también diversas señales fisiológicas de la persona para poder relacionar la información recolectada con cambios producidos en la persona.

El dispositivo de monitorización desarrollado para la medida de las señales fisiológicas consiste en una pulsera de peso muy ligero y fabricada con un material muy suave al tacto para facilitar la tolerancia a su uso en las persona con **TEA**. Los tres dispositivos restantes se encargan de la adquisición de los estímulos del entorno. Por un lado, se ha desarrollado un pequeño dispositivo para la adquisición de las condiciones ambientales del entorno, como son la luminosidad o la temperatura ambiente. Por otra parte, se ha desarrollado una aplicación *Android* que actúa como sensor del ruido ambiente utilizando el micrófono del teléfono donde se ejecuta. Además, también se encarga de gestionar los dispositivos de monitorización anteriores y el almacenamiento de la información, que se realiza en una base de datos remota. El último de los dispositivos desarrollados es un sistema para la medición de estímulos visuales que utiliza una cámara de 360 grados para capturar una imagen de todo el entorno.

El uso de técnicas de [AA](#) para la extracción de información se encuentra en los últimos años en un crecimiento constante debido principalmente a la cantidad de datos casi ilimitados disponibles en el mundo real y la mejora de los dispositivos de procesamiento. Esto permite crear modelos predictivos más robustos y complejos para aplicarlos en cualquier campo de estudio.

En este aspecto, se han utilizado las señales registradas por los dispositivos de monitorización de la plataforma desarrollada para construir conjuntos de datos aplicando la ingeniería de atributos y entrenar modelos predictivos mediante el uso de algoritmos de [AA](#). Con estos modelos se puede extraer información acerca de la persona y su comportamiento, o sobre el propio entorno. Para poner en práctica estos procedimientos se ha realizado una experimentación con personas con [TEA](#) dentro de un entorno clínico donde se ha implantado la plataforma de dispositivos desarrollada. Esto ha permitido validar el correcto funcionamiento de los dispositivos y extraer registros a partir de los cuales trabajar aplicando métodos de [AA](#). Además, también se ha implementado una aplicación web para visualizar y compartir la información registrada durante la experimentación y los resultados obtenidos en ésta.

Finalmente, se ha desarrollado un algoritmo para la reconstrucción de la señal de la [FC](#) cuando la señal de [PPG](#), medida por el dispositivo de monitorización de señales fisiológicas, se corrompe debido a artefactos de movimiento provocados por el movimiento de los dedos y la muñeca de la persona. Este algoritmo nos permite corregir algunos de los problemas surgidos durante la experimentación debido a la tolerancia de las personas con [TEA](#) al uso de cuerpos extraños.

9.2 TRABAJOS FUTUROS

Durante la elaboración de esta tesis doctoral algunas de las líneas de trabajo han quedado abiertas. A continuación, se resumen en los siguientes puntos:

- Continuar con la experimentación en entorno clínico mejorando el protocolo de adquisición durante las sesiones para obtener más información y poder continuar aplicando nuevas técnicas de AA que permitan construir mejores modelos predictivos.
- Realizar una experimentación en entorno doméstico con personas con TEA para poder adquirir información en actividades de la vida diaria llevadas a cabo en el espacio de confort de la persona.
- Integrar el algoritmo desarrollado para la reconstrucción de la FC en un dispositivo que lo ejecute en tiempo real dentro de la plataforma construida.
- Integrar nuevos sensores para la medida de estímulos en la plataforma que puedan resultar relevantes.
- Implementar un cliente remoto que ejecute en tiempo real los modelos predictivos obtenidos para anticiparse a los cambios de conducta de la persona.

CONCLUSIONS

10.1 CONCLUSION

People with an Autism Spectrum Disorder (ASD) also tend to suffer from a Sensory Processing Disorder (SPD) that makes them feel the stimuli of the environment in a different way from the rest of people. Furthermore, these special characteristics depend on each person who suffers from ASD and the situation in which they find themselves at any given moment. Sometimes these people may feel overwhelmed by the stimuli in the environment, causing them to leave their comfort zone and may even lead to a behavioural crisis, especially in children or people with an associated intellectual disability.

To try to monitor these circumstances, a platform has been developed that aims to identify situations where people with ASD are affected by environmental stimuli. This platform is composed of four monitoring devices that measure the environmental stimuli present at any given moment, and also measure various physiological signals of the person in order to relate the information collected with the changes produced in the person.

The monitoring device developed for the measurement of physiological signals consists of a very light-weight bracelet made of a soft-touch material to facilitate tolerance to its use in people with ASD. The other three devices are responsible for the acquisition of stimuli from the environment. On one hand, a small device has been developed for the acquisition of environmental conditions, such as luminosity or environmental temperature. On the other hand, an Android application has been developed which acts as an environmental noise sensor using the microphone of the phone where it's run. In addition, this system also manages the previous monitoring devices and the storage of the information, which is stored in a remote non-relational database. The last of the developed devices is a system for measuring visual stimuli that uses a 360-degree camera to capture an image of the entire environment where the person is located.

The use of machine learning techniques for information extraction is continuously growing in recent years mainly due to the almost unlimited amount of available data in the real world and the improvement of processing devices. This allows the creation of more robust and complex predictive models for application in any field of study.

In that sense, the recorded signals from the monitoring devices of the developed platform have been used to build datasets applying feature engineering and to train predictive models by using machine learning algorithms. These models can be used to extract information about the person and their behaviour, or about the environment itself. In order to put these methods into practice, an experiment has been carried out with people with ASD in a clinical environment where the developed platform of devices has been implemented. This has made it possible to validate the correct operation of the devices and to extract records from which to apply machine learning methods. In addition, a web application has also been developed to visualise and to share the collected information and the results obtained during the experimentation.

Finally, an algorithm has been developed for the reconstruction of the heart rate signal when the Photoplethysmography signal, measured by the physiological signal monitoring device, is corrupted due to motion artefacts caused by the movement of the person's fingers and wrist. This algorithm allows us to correct some of the problems emerged during experimentation due to the lack of tolerance of people with ASD to wear foreign bodies.

10.2 FUTURE WORK

During the development of this doctoral thesis, some of the lines of work have remained open. They are summarised in the following points:

- Continue with the experimentation in the clinical environment by improving the acquisition protocol during the sessions in order to obtain more information and to be able to continue applying new machine learning techniques to build more powerful predictive models.
- Performing an experimentation in home environment with people with ASD in order to acquire information on daily life activities carried out in the person's comfort environment.
- Integrate the developed algorithm for heart rate reconstruction into a real time device within the built platform.
- Integrate new sensors for the measurementn of new stimuli on the platform that may be useful.
- Implement a remote client that executes in real time the obtained predictive models to predict changes in the person's behaviour.



CONTRIBUCIONES PRINCIPALES

La presente Tesis Doctoral está sustentada por un compendio de trabajos previamente publicados en revistas de impacto, indexadas según Scimago Journal & Country Rank. El cuerpo de dicha tesis queda constituido por los siguientes artículos, cuyas referencias bibliográficas completas se indican a continuación:

Vicente-Samper, J. M.; Ávila-Navarro, E. y Sabater-Navarro, J. M. (2020), «Data Acquisition Devices Towards a System for Monitoring Sensory Processing Disorders», *IEEE Access* 8, págs. 183596-183605, DOI: [10.1109/ACCESS.2020.3029692](https://doi.org/10.1109/ACCESS.2020.3029692)

- Título de la revista: IEEE Access (ISSN: 2169-3536)
- Factor de impacto SJR (2020): 0,587
- Categoría: Engineering (miscellaneous), Cuartil Q1 (82/365).

Vicente-Samper, J. M.; Avila-Navarro, E.; Esteve, V. y Sabater-Navarro, J. M. (2021), «Intelligent Monitoring Platform to Evaluate the Overall State of People with Neurological Disorders», *Applied Sciences* 11(6), DOI: [10.3390/app11062789](https://doi.org/10.3390/app11062789)

- Título de la revista: Applied Sciences(ISSN: 2076-3417)
- Factor de impacto SJR (2020): 0,435
- Categoría: Engineering (miscellaneous), Cuartil Q1 (110/365).

A continuación se anexan los documentos correspondientes a dichas publicaciones.

Received September 9, 2020, accepted October 2, 2020, date of publication October 8, 2020, date of current version October 19, 2020.

Digital Object Identifier 10.1109/ACCESS.2020.3029692

Data Acquisition Devices Towards a System for Monitoring Sensory Processing Disorders

JOSE MARIA VICENTE-SAMPER¹, (Graduate Student Member, IEEE),

ERNESTO ÁVILA-NAVARRO², AND

JOSE MARIA SABATER-NAVARRO¹, (Senior Member, IEEE)

¹Department of Systems Engineering and Automation, Miguel Hernández University of Elche, 03202 Elche, Spain

²Department of Materials Science, Optics and Electronic Technology, Miguel Hernández University of Elche, 03202 Elche, Spain

Corresponding author: Jose Maria Vicente-Samper (jose.vicentes@umh.es)

This work was supported in part by the Spanish Research State Agency and European Regional Development Fund through “Craneecal” Project (DPI2016-80391 C3-2-R).

ABSTRACT People with autism spectrum disorder (ASD) manifest great heterogeneity in their atypical sensory behaviors. It is estimated that 95% of people with ASD have a Sensory Process Disorder (SPD). People with ASD feel the need to control what happens in their environment. However, it is inevitable that new situations occur during a person’s daily life. Therefore, it is important to monitor most of the circumstances they face in an attempt to predict the appearance of disorders that end up affecting their behavior. This paper presents the first steps towards the development of a system for knowing the value and effect on the SPD of different biological and environmental parameters. To obtain those variables, two electronic devices have been designed. The first one is an electronic system for capturing environmental variables such as luminosity or humidity, which is portable and mobile. The second electronic device is a soft wearable wristband which gets biological parameters. To know the effect of those variables on the SPD, a complete software platform has been implemented. Both devices upload day-to-day data to a cloud database where the information is stored in timeseries data of different parameters. The system uses the data to learn a personalized model that is designed to manage the SPD of the user. The main novelty is the use of sensor integration, data processing and machine learning techniques to develop a system able to classify the sensory load supported by a user with ASD while performing different activities. The results obtained so far prove the feasibility of the approach.

INDEX TERMS Autism spectrum disorder, Bluetooth low energy, machine learning, PPG, sensory processing disorder, wearable devices.

I. INTRODUCTION

According to the World Health Organization (WHO), currently 1 in 160 children is diagnosed with an Autism Spectrum Disorder (ASD) [1], [2]. A figure that could even become higher, since ASD prevalence in many low-income countries remains currently unknown. The appearance of ASD makes no distinction of race, ethnicity or socioeconomic group. However, it is statistically 4–5 times more present in males than in females. In addition, roughly 30% - 50% of people with ASD have an associated intellectual disability (IQ < 70) [3], [4].

The associate editor coordinating the review of this manuscript and approving it for publication was György Eigner¹.

Behavior incidents, sleep or loss of attention are common problems in people with ASD, and they are directly related to the great heterogeneity in their atypical sensory behaviors. Sensory integration can be defined as the organization of sensory information for its use [5]. It is a neurological process that allows the individual to make sense of the environment that surrounding them. However, it is estimated that 95% of people with ASD also present a Sensory Processing Disorder (SPD) [6]–[8]. These problems are related to difficulties in social interaction, learning, and behavior in a person with ASD [9]. In the Diagnostic and Statistical Manual of Mental Disorders (DSM-V) of the American Psychiatric Association, alterations to sensory stimuli or an unusual interest in sensory aspects of the environment are recognized as diagnostic

criteria for hypo- or hyper-reactive ASD [10]. The way to respond to a stimulus can be different depending on the individual. For example, someone may be extremely sensitive to certain sounds which are usually deemed to be soft sounds by the majority. The same applies to some visual, tactile, olfactory or gustatory stimuli. Everyday activities development is significantly affected by sensory alterations, which can also play an important role towards challenging behavior and social isolation [11]. Most of behavior incidents occur as a consequence of the discomfort the person feels due to a negative stimulus. Considering the hypersensitivity in some senses often found in people with ASD, any change in the environment is likely to trigger a defiant, hysterical and sometimes aggressive behavior, which should be intervened [12]. When talking about intervention, it is defined as “any responding method to behavior that implies some degree of physical force aimed to limiting or restricting movement or mobility” [13], to prevent the individual from injuring themselves or others.

It is inevitable that new situations will arise in a person’s daily life. Nevertheless, having a personalized knowledge of the effect of those daily variables that significantly affect the person could help in several aspects. The pharmacological treatment used to mitigate derived problems such as sleep or hyperactivity could be better adjusted if a continuous monitoring of biological parameters is available, or a predictive model that was continuously monitoring environmental parameters surrounding the person would help to predict a problem in SPD crises. Therefore, trying to know the variables of the environment where the person is, as well as some biological variables of the individual, could allow to have a greater control of the possible situations and it could help to detect new causes that produce those behavioral changes in them.

The purpose of this work is to establish the first steps towards the implementation of a complete system able to know the value and effect on the SPD of different biological and environmental parameters. Figure 1 sketches the concept of this work. The main challenges that this work faces are firstly to decide which are the interesting variables to measure, i.e. which ones can provide information about the physical state of the individual and the environment. Once the variables have been selected, we propose the required electronics to measure those variables and a software platform to manage these data. The aim is to use this information to learn a personalized model that is designed to manage the SPD of the user. To validate the system before being used by people with ASD, an experimentation is performed.

The paper is organized as follows. In the materials and methods section, the study made for identifying the interesting variables in the system is presented. Then, two electronic devices are introduced. The first one is an electronic system for capturing environmental variables, which is portable and mobile. The second electronic device is a soft wearable wristband which obtains biological parameters. Section II-D presents the software environment for uploading

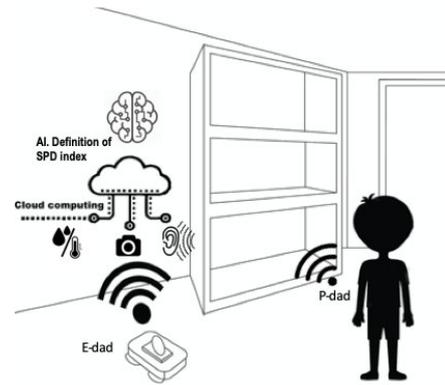


FIGURE 1. General concept of the proposed system.

the information and the structure of the stored data. Section II-E proposes a system validation through an experimentation with users and a machine learning classifier. Section III shows the results of the system validation and the functional tests made to evaluate the energy consumption of the electronics and the reliability of the uploading process in a real scenario. Finally, in Section IV the obtained results are discussed and the use of the system is evaluated.

II. MATERIALS AND METHODS

This section describes the complete design of the system that comprises two electronics devices, an uploader app and a remote cloud computing software (Figure 1). The system is designed to deal with two kinds of variables: the stimuli that can affect the state of the individual and the physical parameters that reveal this state. The idea behind the monitoring of physical or emotional state of the patient is to use this information for learning purposes in a personalized model. Besides, the parameters to be measured have been classified as environmental or personal variables. Due to the reluctance of people with ASD to carry foreign bodies, not all the patients will be able to carry bulky (or even little) wearables. This classification allows to use a modular (and personalised) solution in the acquisition data device design by splitting the solution into modular electronics. Therefore, it seems appropriate that the measurement system is divided into two different devices, one for environmental measurement and the other for the personal parameters under measurement. To finish this section and once the design of the devices has been presented, a validation of the system is proposed through tests carried out by volunteer users without ASD.

A. EVALUATION OF MEASURABLE PARAMETERS

First, it is necessary to decide which variables are relevant to be measured by the system. Thus, a study about the different interesting variables to measure in the system was made. The study initially enumerates nearly all the possible stimuli that can affect the state of a person with ASD. The enumeration also included some physiological parameters that allow to know the physical state of the user. All these variables were

TABLE 1. Measurable parameters studied for the system.

	Personal	Environment	Reason	Consequence	Ease of measurement	Ease of integration	Clinical assignment	Selected variable
Educational variables	✓	✓	✓		No	No	9	No
Biological variables	✓		✓		No	No	8	No
Amount of people in the environment		✓	✓		No	Yes	10	Yes
Relationship with people in the environment		✓	✓		No	No	8	No
Body temperature	✓			✓	Yes	Yes	-	Yes
Ambient temperature		✓	✓		Yes	Yes	8	Yes
Atmospheric pressure		✓	✓		Yes	Yes	0	Yes
Relative humidity		✓	✓		Yes	Yes	0	Yes
Luminosity		✓	✓		Yes	Yes	6	Yes
Heart rate	✓			✓	Yes	Yes	-	Yes
Ambient noise: Sonority		✓	✓		Yes	Yes	10	Yes
Ambient noise: Frequency		✓	✓		Yes	Yes	10	Yes
Electrodermal activity	✓			✓	Yes	No	-	Yes
Textures	✓		✓		No	No	5	No
Human contact	✓		✓		No	No	10	Yes
Smells		✓	✓		No	Yes	8	No
Flavors	✓		✓		No	No	6	No
Physical activity	✓		✓	✓	Yes	Yes	6	Yes
Electromyography activity	✓			✓	Yes	No	-	No
Visual stimulation: Colors		✓	✓		No	Yes	1	Yes
Visual stimulation: Shapes		✓	✓		No	Yes	1	Yes
Visual stimulation: Rate		✓	✓		No	Yes	3	Yes
Body balance	✓		✓		No	No	5	No
Proprioception	✓		✓		No	No	8	No

evaluated according to different characteristics to decide if they are incorporated into the acquisition device. The information used in the study is collected in Table 1. The two first columns of the table specified if the parameter is measured from the environment or from the user. This determines in which of the devices will be integrated the measurement in case the variable is selected. The two following columns indicate if the parameter is a stimulus that will have influence on a change of the user’s physical status (reason) or whose modification implies that there has already been a change in the user’s status (consequence). The ”Clinical assignment” column points out one of the most important aspects of the study. It presents a numerical assignment, being 10 the highest mark, about how likely is the variable to have impact in a change on the user’s status. The values shown have been allocated in collaboration with professionals from the Infanta Leonor Center for people with ASD in Alicante, Spain. Table 1 includes two parameter collections, Educational and Biological variables, that can affect the physical and cognitive state of the user and they depend on many factors. They are considered as modifiers because is not feasible to integrate them directly in the monitoring device. Table 2 shows the detail of the main factors that correspond to these collections.

A total of 24 variables have been studied, 12 of which were classified as personal and 13 as environmental (educational variables may be considered as personal and environmental). Of these, 20 parameters have been considered as possible reason for changes in the user, while the remaining 5 have been classified as variables that measure changes in the user’s

TABLE 2. Main factors of the educational and biological variables.

Biological variables	- Medication - Nutrition - Hormonal fluctuations - Rest
Educational variables	- Schedule - Spontaneous occurrence - Make a choice - Activities

status. From all the variables, it has finally been decided to select 15 to be integrated into the monitoring system. Four of them will be integrated in the personal device and the remaining eleven in the environmental device.

B. ENVIRONMENTAL DATA ACQUISITION DEVICE

The environmental monitoring system is in charge of obtaining the previously selected environment stimuli values. The device is currently composed of a small electronic equipment sizing 40 × 35 × 10 millimeters, along with an Android smartphone. The electronic device integrates sensors for four variables acquisition: luminosity, atmospheric pressure, relative humidity and ambient temperature. On the other hand, the smartphone, besides managing the whole system of acquisition and sending information to a database, it also acts as a sound sensor, measuring two other variables of the environment: sonority and frequency of the ambient noise. Parameters related with camera sensor (visual stimulation,

amount of people in the environment) or physical activity are pending to implement.

The sensors in the electronic device do not require any signal processing since their digital outputs return the value of the sensed parameter. All the information collected by the sensors is sent through Bluetooth Low Energy (BLE) to the smartphone. The sample rate of the atmospheric pressure, relative humidity and ambient temperature is one data every five minutes. For the luminosity, the sensor takes a measurement every ten seconds, given that people with ASD seems to be seriously affected by luminosity changes. The most often reported visual sensitivities are sensitivity to bright light, fluorescent light, colours and certain patterns (especially stripes) [14].

The sound analysis is done with the microphone of the smartphone that manages the system and with the help of the TarsosDSP library for audio processing, that works in Java [15]. First, a capture is made through an audio service that collects the sound spectrum from 60 Hz to 20 kHz, which is the optimal operating values range of the digital microphone. A sample rate of 44100 Hz is used to capture any sound within the human audible spectrum (20 Hz to 22 kHz), with a buffer size of 2048. Then, the Fast Fourier Transform (FFT) of the stored signal in the buffer is calculated and the module of the bins returned by the FFT is computed. Subsequently, an Aweighting filter [16] is applied to the calculated magnitudes. After that, the bins are separated into octaves [17]. Each of them stores information from a range of frequencies. These ranges have been calculated for a Full-Octave and 10 bands. Table 3 shows the division of the octaves, together with the lower, center and upper frequency of each band. The bands 0, 1 and 2 have been merged into a single band because the energy in very low frequencies is small due to the operating range of the microphone. Once the information is divided into octaves, the accumulated energy of each band is calculated with the Parseval’s Theorem [18], [19]. The values of each octave, in dB-A, are stored in a different array. Every 10 seconds, it is calculated the average and the variance of each array and the results are stored in a final array in an arranged manner. This array is the searched result for the audio process.

TABLE 3. Octave Bands Division.

Band Number	Lower Band Limit (Hz)	Center Frequency (Hz)	Upper Band Limit (Hz)	Bin Range
0	22	31.5	44	0 - 0
1	44	63	88	1 - 2
2	88	125	177	3 - 6
3	177	250	355	7 - 14
4	355	500	710	15 - 30
5	710	1000	1420	31 - 62
6	1420	2000	2840	63 - 126
7	2840	4000	5680	127 - 254
8	5680	8000	11360	255 - 510
9	11360	16000	22720	511 - 1023

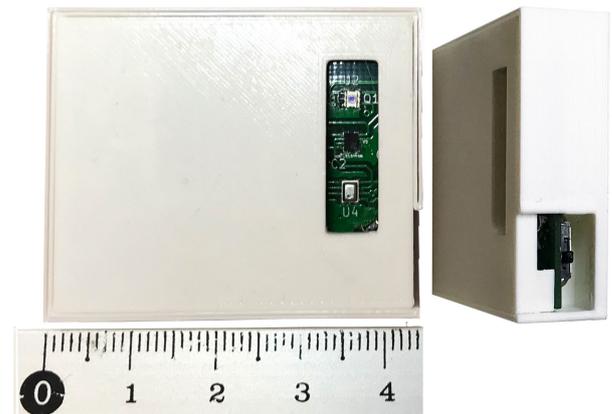


FIGURE 2. Environmental Data Acquisition Device.

Figure 2 shows an image of the electronic device for environmental data acquisition. The device is made up of an electronic board inside a casing. The sensors are located in an uncovered part so the values are correctly measured from the environment. On one of the sides, it has a switch to turn the device on and off. It has a blue led to indicate that it is powered on. The device is powered by a CR2032 coin battery. The smartphone that complete the environmental data acquisition system only needs to be an Android device with BLE communication.

C. PERSONAL DATA ACQUISITION DEVICE

The personal monitoring equipment (Figure 3) is an electronic device that can be placed on the user’s wrist using a soft envelope. The device casing, which is 35 × 25 × 10 millimeters in size, has been lined with a soft and spongy material to make it ergonomic to wear. The electronic device integrates measurement systems for the acquisition of two of the previously selected personal variables: body temperature and heart rate (HR). The other two selected variables, electrodermal activity and human contact are currently under development. To turn off the device, a button allocated at the bottom side must be held down for 8 seconds. This procedure prevents the equipment from shutting down due to a wrong tap. On one of the sides there is a hole from where it can be seen a soft light from a blue led which indicates that the device is on. The device integrates BLE communication to



FIGURE 3. Personal Data Acquisition Device.

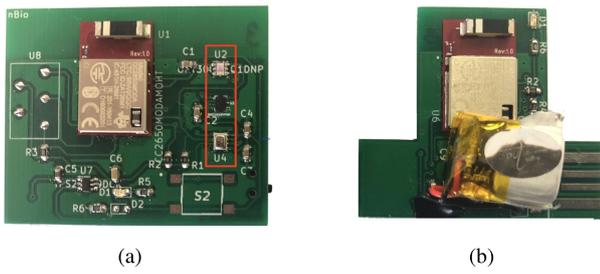


FIGURE 4. View of the developed electronics: (a) Environmental electronics; (b) Personal electronics.

send all the acquired data to the smartphone that controls the whole system. In addition, it is powered by a 60 mAh Li-ion battery. To charge the device battery, one of the belt clamps must be removed. There is a USB port that plugs into an adapter. This allows the system to be charged with the smartphone’s charger. Figure 4 shows a picture of the integrated electronics into the monitoring devices. The area marked with a red rectangle in Figure 4a is the sensor zone shown in Figure 2.

The sensor for the body temperature measurement does not require any signal processing. The sensor is specifically designed for the measurement of the human body temperature. It provides an accuracy of 0.1 °C in the range of 37 °C to 39 °C, complying with the ASTM E112 Standard Specification for Electronic Thermometer for Intermittent Determination of Patient Temperature [20]. The sample rate of the sensor has been established in one measurement every 5 minutes. The variability of human body temperature is slow, despite the fact that the temperatures regularly cycle up and down along the day, controlled by circadian rhythm [21], [22].

For the measurement of the HR an optical sensor that provides the user’s photoplethysmography (PPG) was used. Pulses of light irradiate the skin and the change in light absorption is used to detect changes in blood volume in the microvascular tissue. Different parameters can be provided from this signal, including the HR. The PPG signal is very sensitive to poor blood perfusion of the peripheral tissues and to motion artifacts. Thus, in order to calculate the user’s HR it is necessary to process the original PPG signal provided by the optical sensor [23]. The processing of HR signal is as follows: firstly, a 6-seconds window of the raw PPG signal is stored. Once the data window is complete, a bandpass filter is applied to remove the high frequency noisy components, like power artifacts, as well as low frequency components noise due to temperature variations or changes in capillary density. The bandpass filter frequency range is from 0.6 Hz to 3 Hz, fundamental frequency range of HR. Then, a median filter is applied to delete the sudden spikes. And finally, a lowpass finite impulse response (FIR) filter is applied to smooth the signal and to remove the baseline. Figure 5 illustrates the different processing steps of the PPG signal until a clear signal is achieved. Once the signal processing is cleared, the FFT obtains its frequency response. Finally, the heart rate,

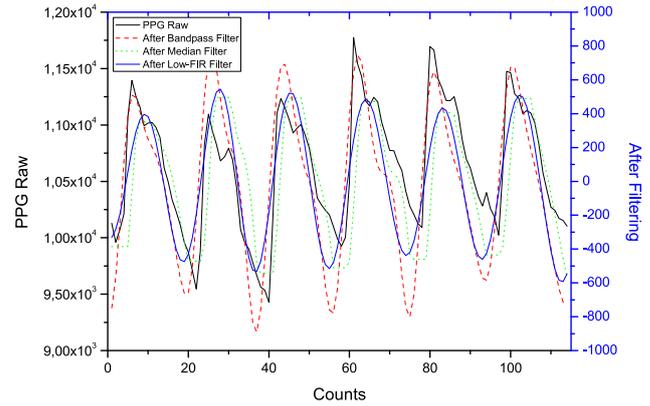


FIGURE 5. PPG Signal Processing.

in Beats-Per-Minute (BPM), is estimated as:

$$HR = f_0 * 60 \tag{1}$$

where f_0 is the fundamental frequency of the PPG signal.

D. SOFTWARE

The management of the whole system is performed with our own developed Android application installed on a smartphone. In addition, the smartphone is used as sound sensor, as explained in previous points, and receives the information obtained by the sensors of the acquisition devices via BLE.

The received data from the sensors are arranged to be stored in a database. This is a non-relational MongoDB database where information is stored in data collections. There is a different collection for each of the integrated variables in the monitoring system. Each stored document includes the value of the variable and the timestamp of the sample. The use of a non-relational database increases the versatility of the data. It allows adding new fields in the documents of a collection if necessary without the need of making changes. In addition, it is equipped with internal algorithms for data queries that speed up the access to the information. This feature is important for generating timeseries data of parameters.

On the other hand, the application interface shows the basic information to the user’s caregiver to check the correct operation of the system. Figure 6 shows a screenshot of the interface. At the top it can be seen the connection status with the data acquisition devices. The caregiver has a button called “Activity” that must be pressed to create a timemarker when the patient suffers a change in behavior. In that way, the information will be available to relate the user change with the stimuli that surround them at that moment.

In addition, the last sampled values of the different variables are displayed on the interface as information. The application also warns of the acquisition devices disconnection, as well as the lack of internet connection for uploading documents to the database.

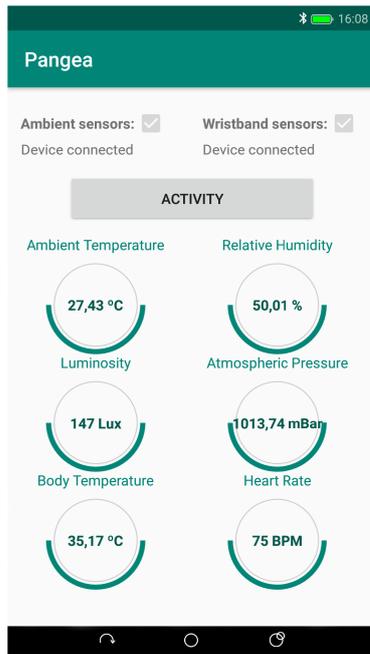


FIGURE 6. Android Application Interface.

E. VALIDATION OF THE SYSTEM

To assess the performance of the full system an experimentation is presented. By means of this, an attempt is made to validate the correct operation of the monitoring devices and to generate a machine learning (ML) model capable of providing information with the data taken by the sensors during different activities comparable to those of the daily life of a child with ASD.

It is proposed to train a machine learning model that is capable of solving what activity is the user performing at each moment only with the information obtained by the sensors of the monitoring devices. For this purpose, it is necessary to record a large amount of data that allow the model to be properly trained and to adequately select among the different possible types according to the behavior. For data collection, a protocol of 9 controlled activities has been designed with a total duration time of 210 minutes. Next, the different activities are shown together with the expected result of the stimuli and the duration time for each one of them.

1) **Brushing teeth (5 minutes)**

It is a daily activity that is fully integrated into the daily routine of users. It should not generate stress, and also its duration is short in time.

2) **Outdoor walk (30 minutes)**

It consists of taking a walk outdoors during the day, with ambient light and sound from the street. It is a common activity and it occurs during any journey to school or to a relatives's home. There is a high luminosity due to sunlight. The ambient sound is greater than that registered in the home or closed spaces of non-public concurrence or with an agglomeration of people, and it may high at specific times due to traffic,

construction, etc. The environmental temperature can be high in summer months, and low in winter and the heart rate should accelerate with respect to "physical rest" activities.

3) **Power walking (15 minutes)**

It is about increasing the speed of the walk from the prior activity, doing a brief sports activity. The stimuli from the environment keep similar to the previous activity. The heart rate must accelerate and therefore, it will be higher. Body temperature should also rise during activity.

4) **Watching TV on the couch (45 minutes)**

It consists of viewing a program that the user likes, with the sound of television and ensuring that there are no other external stimuli that distract him from the activity. The volume should be moderate and the activity should be relaxing and comfortable for the user. It is considered a leisure activity. The luminosity must be low, with possible small changes due to the light coming from the television. The sound should also be low and only coming from the television. The heart rate should drop during this activity, as well as the body temperature. The stimuli from the home must be comfortable for the user.

5) **Homework, Academic activities or Crossword puzzles (20 minutes)**

It is about the user solving tasks that may generate them some stress, without the task becoming annoying to solve. It could be considered as a daily activity of the user. The level of difficulty will be different for each user and there is the possibility that the user has background music with a low sound level. There should be no other stimuli that distract the user from the activity. The luminosity will be medium, i.e. with appropriate values for working or studying. The sound will be low, and there may be slight changes if it is done with pleasant music at low volume. The heart rate and the body temperature should be low. The stimuli from the home must be comfortable for the user.

6) **Playing video games (30 minutes)**

It consists on the user playing a video game that they like and with a sound that is not necessarily low, which helps to stimulate them. It is considered as a leisure activity. The user must be stimulated by the game. The luminosity will be low. The sound can be raised to help to introduce the user to the game. The stimuli from the home must be comfortable for the user. The body temperature will have low values, although it can increase with respect to "rest activities" due to the stress that the game can generate in the user. The heart rate can grow and maintain medium-high values also due to the stress generated by the game.

7) **Have a snack (20 minutes)**

It is a daily activity. The user has a snack while sitting in a chair accompanied by a friend or a family member. There should be no more external stimuli.

The luminosity will be low, the usual one in the kitchen, the living room or the dining room of the house. There should be no external sound, only a pleasant conversation with a family member or friend, so the values will be relatively low. The stimuli from the home must be comfortable for the user. The heart rate and the body temperature will have low values.

8) **Read in silence (30 minutes)**

The activity tries to make the user relax in silence by reading a book or comic of their like without any external stimuli. It is considered a daily and leisure activity. Environmental stimuli should be minimal and comfortable for the user. The luminosity will be medium, i.e. with adequate values for reading. The sound will be very low, desirably zero. The heart rate and the body temperature will have low values.

9) **Power walking (15 minutes)**

To finish, the user performs a brief sports activity again. The stimuli will be similar to activity 3, although the environmental conditions may have changed somewhat.

Once the protocol for experimentation has been established, it is time to organize the collection of information with different users who will carry out the test. Users must sign a document of compliance giving their explicit consent to the researchers to use the physiological data collected during the test. The experimentation complies with the Ethical Principles for Medical Research Involving Human Subjects from the Declaration of Helsinki. In addition, for the storage of the information, a secure database is used to comply with the Data Protection Act involving security systems to protect the information.

The tests have been made by five healthy volunteers without ASD in their home to ease a higher comfort and naturalness in the user (Table 4 shows more information about the users). Each one of the users has repeated the experimentation several times to be able to generate as large as possible dataset to train the model.

TABLE 4. Information about the users.

Gender	Age (Years)	Repeatability (Times)
Male	28	3
Female	24	1
Female	29	2
Male	32	2
Male	45	1

During experimentation the sample rate and the data storage period is different for each variable. Therefore, once the experimentation is finished, the stored user data must be processed so that there is a temporal correlation of the information. To do this, the values of the variables with the lowest sampling rate are completed (thus selected by the natural latency in the signal change). The necessary number of duplications is added until the amount of data is equal to the variables with a higher sampling and storage rate. This is

possible because each activity takes place without changing the environment.

When all the variables are temporally correlated, a series of statistical parameters is calculated for each of them (*Mean, Median, Standard Deviation, Mean Absolute Deviation, Signal 25th Percentile, Signal 75th Percentile, Signal Inter Quantile Range, Skewness, Kurtosis, Mode, Trimmed Mean, Geometric Mean, Harmonic Mean, Variance, Derivative*). These parameters will be the input of the ML model to determine which activity is performing the user. To calculate these parameters, the variables have been divided into the corresponding periods of each activity and subsequently divided into information sub-periods. This helps to eliminate noise or possible erroneous readings in the sensors that can also be due to the activities carried out during the experimentation. Therefore, this will provide the required information to the classifier to determine the activity. In the environmental variables with duplications due to their low sampling rate only the value and the derivative of the signal are used as parameters. All these parameters will compose the Dataset used to train a supervised learning classifier.

In total, there are 66 parameters that make up the Dataset table. Therefore, each of the entries will be made up of 66 columns with the values of the parameters previously calculated for a given moment and an extra column, called class, which will indicate the number of the activity that corresponds to the entry.

For the study and training of a ML model that acts as a classifier, the *Classification Learner* application from Matlab® has been used [24]. This software allows to train different classification models in a simple and fast way. In addition, it provides different tools to assess the behavior of the model and to select the most appropriate type for the application.

The Dataset has been split into two parts. The main part will be used for model training (training set), whilst the remaining data are reserved for a validation of the model (test set). It has been decided that 30% of the data will be used for validation and the remaining 70% will form the training set. To do the split, an algorithm for random data partitions for cross validation has been used.

III. RESULTS

This section attempts to reveal the obtained results in the system validation test. The acquisition devices have been collecting data and storing them in the database during the tests. The environmental device was moved from place to place together with every test user during the experimentation. The personal monitoring device was attached to the user’s wrist.

The average power consumption of the ambient device is 650 μ A. A low power consumption that allows an autonomy of more than one month of operation with only one battery. On the other hand, the personal device has an average power consumption of 6.5 mA. During the tests it has shown an autonomy of more than 10 hours and the charging time of the device is 50 minutes.

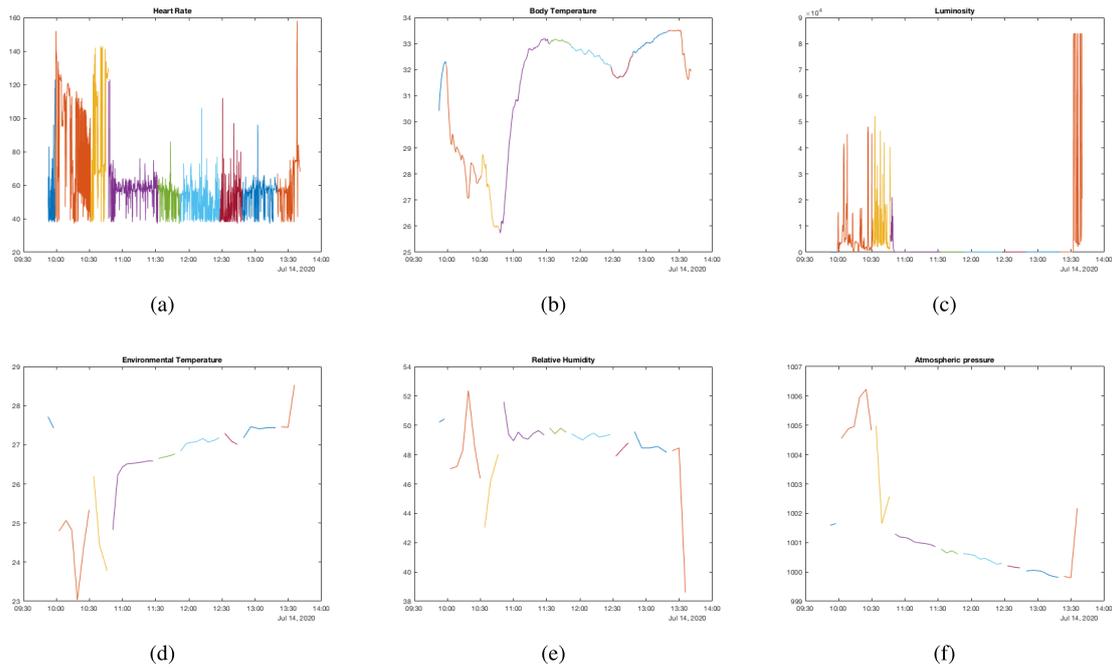


FIGURE 7. Raw data taken by the sensors during a test: (a) Heart rate; (b) Body Temperature; (c) Luminosity; (d) Environmental Temperature; (e) Relative Humidity; (f) Atmospheric Pressure.

TABLE 5. Summary of the activity-recognition results using different machine learning algorithms.

ML Algorithm	Accuracy (%)	Training Time (sec)	ML Algorithm	Accuracy (%)	Training Time (sec)
Tree	64.4	1.2908	KNN	64.2	2.7833
Linear SVM	51.5	3.2088	Cubic KNN	49.8	4.1146
Gaussian SVM	60.7	2.9499	Weighted KNN	58.1	1.3995
Quadratic SVM	65.9	1.7088	Bagged Trees	81.7	2.6963
Cubic SVM	65.9	1.8907	Subspace KNN	67.7	4.2318

The personal device is comfortable to wear due to its reduced size and the soft lining. It is essential to reduce the impact of the system on the user so that the devices do not become a negative stimulus according to the future use of people with ASD.

During experimentation, the behavior of the devices was correct. The reliability of uploading data to the database has been tested. Proper management of information will allow to generate better timeseries. In this way, personalized models for prediction will be more effective. When there is a loss in the internet connection, the documents pending for uploading to the database are queued at the smartphone to be uploaded once the connection has been recovered. The users performed the activities without any problem and the data was stored without loss of information. Figure 7 shows the raw data collected by the sensors during a test carried out by one of the users (the sound is not shown to simplify the figure).

The different colors represent the time period corresponding to each of the experimentation activities. The graphs with non-continuous signals correspond to the variables with the lowest sampling rate. The gaps are due to a piecemeal representation of the signal.

The data obtained from all the experimentations with users have been processed to obtain the information dataset. The dataset has 901 observations extracted from the 9 tests carried out. The number of observations available for each activity is different. There is a greater number for those activities where the time period is longer (which affects the results).

The studied ML models are of the Decision Tree, Support Vector Machines (SVM), K-nearest Neighbor (KNN) and Ensemble Learning types. Table 5 shows a summary of the main analysed algorithms with the *Classification Learner* tool and the results obtained during training.

The training time is a crucial quality that allows the model to be optimized. For a considerably large dataset, the training time can be extended for an excessive amount of time because the information load is too heavy. Thus, the prediction rate will decrease. Although the dataset used for validation is not large, the training times shown in Table 5 give an idea of how they can vary according to the used algorithm. The used algorithms have been maintained with the default characteristics imposed by the *Classification Learner* tool. This tool allows to modify parameters of the models to improve their response in the prediction. However, when the model is more

complex, the training times increase and the prediction rate decreases. Therefore, a trade-off solution must be reached that allows to obtain high prediction success rates, while avoiding excessively long computational time.

IV. DISCUSSION

Among all the analysed algorithms, the model that provides the best results is the Bagged Trees model, of the Ensemble Learning type and made up of multiple Decision Trees. With a number of learners of 100 has a prediction speed of ~4500 observations/sec. This model has shown an 81.7% accuracy in the validation predictions after the training. As a result of the validation of the model, the confusion matrix is shown in Figure 8.

Activity 1	85.71	0	0	0	0	0	0	14.29	0
Activity 2	0	93.33	3.333	3.333	0	0	0	0	0
Activity 3	0	61.11	38.89	0	0	0	0	0	0
Activity 4	2	4	0	90	0	2	0	0	2
Activity 5	0	0	0	8	92	0	0	0	0
Activity 6	0	0	0	3.448	3.448	86.21	6.897	0	0
Activity 7	0	0	0	4.348	4.348	8.696	78.26	4.348	0
Activity 8	0	0	0	0	3.448	3.448	0	89.66	3.448
Activity 9	0	5.556	0	0	22.22	0	0	5.556	66.67

FIGURE 8. Detailed activity-recognition results of the Bagged Trees model (Percentages).

It can be seen how the activities that have a greater number of observations generally have a higher accuracy in the predictions than those with a lower number of observations. It is worth noting the low success rate for Activity 3, mistaken by the model for Activity 2. On the one hand, this may be due to the age of the users. As they are mostly young and active people, they do not show a significant change in physical effort when performing the activity. On the other hand, linking both activities and having such a short time period for Activity 3 prevents seeing a growth in the heart rate until half the activity period, thus maintaining similar values to those of Activity 2.

The other activity with less precision is Activity 9. Indeed, this activity consists of doing the same as in Activity 3. These activities have been singled out to present errors in the detection more easily. In the case of Activity 9, something similar to Activity 3 occurs. There is a latency of the user’s effort to appear in his heart rate. Therefore, a part of the time activity period maintains a low heart rate and this causes it to be mistaken for other activities. In general, it would also be positive to have more information in order to have a more complete dataset that allows to train in a more effective manner the ML models.

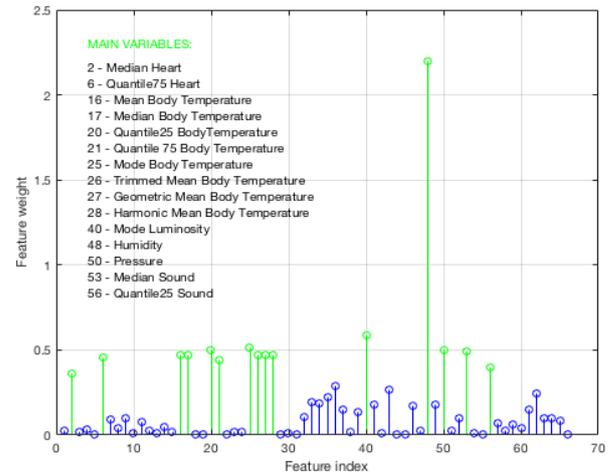


FIGURE 9. Feature weights as a result of the Neighborhood Component Analysis algorithm.

It is also interesting to analyze which are those input variables to which the model gives greater feature weight in the prediction algorithm. For this, the Neighborhood Component Analysis (NCA) Algorithm [25] has been used. Figure 9 shows a graph with the feature weights of each of the 66 predictors. The most notable variables are also listed in Figure 9. In a system where more optimization is required, the variables that contribute the less in the prediction could be excluded. This allows to lighten the model and therefore the response time.

As it has been shown, the system works correctly. The monitoring devices collect the information in a proper way and it is stored for further processing. Despite not having a very large dataset, it has also been possible to demonstrate that variables can be calculated from the stimuli taken by the sensors that allow to classify different states automatically. Therefore, this methodology allows to keep on working towards the use of the system to assess changes in the behavioral state of a person with ASD due to environmental stimuli.

Once the proposed system has been demonstrated to work in a proper manner, we envision that the ML model will be used to generate personalized sub-models for the prediction of the sensory load perceived by a person with ASD. The generic model identifies the activity the person is involved in. Within each activity there is a ML sub-model with a specific admissible sensory load threshold for the person and the activity. Using the above-mentioned procedure, the Feature Weights of the parameters of each sub-model could also be obtained so that, for each activity, a linear model may be defined considering these weights. This model could be used as a predictive model for the behavior of the person.

ACKNOWLEDGMENT

The authors would like to thank the Infanta Leonor Center for people with ASD and the Autism Parent Association of the Valencian Community for their collaboration

and the work they do. Jose Maria Vicente-Samper would like to thank the economic support of the Conselleria d'Educació, Investigació, Cultura i Esport (GVA) through FDGENT/2018/015 project.

REFERENCES

- [1] Autism Spectrum Disorder. (2018). *National Institute Of Mental Health*. Accessed: Feb. 1, 2019. [Online]. Available: <https://www.nimh.nih.gov/health/topics/autism-spectrum-disorders-asd/index.shtml>
- [2] Autism Spectrum Disorders. (2017). *World Health Organization*. Accessed: Apr. 15, 2018. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/autism-spectrum-disorders>
- [3] D. L. Christensen, D. A. Bilder, W. Zahorodny, S. Pettygrove, M. S. Durkin, R. T. Fitzgerald, C. Rice, M. Kurzius-Spencer, J. Baio, and M. Yeargin-Allsopp, "Prevalence and characteristics of autism spectrum disorder among 4-year-old children in the autism and developmental disabilities monitoring network," *J. Develop. Behav. Pediatrics*, vol. 37, no. 1, pp. 1–8, Jan. 2016.
- [4] Data & Statistics on Autism Spectrum Disorder. (2018). *Centers for Disease Control and Prevention*. Accessed: Apr. 16, 2018. [Online]. Available: <https://www.cdc.gov/ncbddd/autism/data.html>
- [5] A. J. Ayres, *Sensory Integration and Learning Disorders*. Western Psychological Services, 1972. [Online]. Available: <https://www.ncbi.nlm.nih.gov/nlmcatalog/362461>
- [6] B. A. Pfeiffer, K. Koenig, M. Kinneale, M. Sheppard, and L. Henderson, "Effectiveness of sensory integration interventions in children with autism spectrum disorders: A pilot study," *Amer. J. Occupational Therapy*, vol. 65, no. 1, pp. 76–85, Jan. 2011.
- [7] S. R. Leekam, C. Nieto, S. J. Libby, L. Wing, and J. Gould, "Describing the sensory abnormalities of children and adults with autism," *J. Autism Develop. Disorders*, vol. 37, no. 5, pp. 894–910, May 2007.
- [8] A. E. Z. Baker, A. Lane, M. T. Anglely, and R. L. Young, "The relationship between sensory processing patterns and behavioural responsiveness in autistic disorder: A pilot study," *J. Autism Develop. Disorders*, vol. 38, no. 5, pp. 867–875, May 2008.
- [9] M. D. Thyne, H. M. Bednarz, A. J. Herringshaw, E. B. Sartin, and R. K. Kana, "The impact of atypical sensory processing on social impairments in autism spectrum disorder," *Develop. Cognit. Neurosci.*, vol. 29, pp. 151–167, Jan. 2018.
- [10] American Psychiatric Association, *Diagnostic and Statistical Manual of Mental Disorders*, 5th ed. American Psychiatric Pub, 2013. [Online]. Available: <https://www.psychiatry.org/psychiatrists/practice/dsm>
- [11] S. A. Cermak, C. Curtin, and L. G. Bandini, "Food selectivity and sensory sensitivity in children with autism spectrum disorders," *J. Amer. Dietetic Assoc.*, vol. 110, no. 2, pp. 238–246, Feb. 2010.
- [12] A. P. Hill, K. E. Zuckerman, A. D. Hagen, D. J. Kriz, S. W. Duvall, J. V. Santen, J. Nigg, D. Fair, and E. Fombonne, "Aggressive behavior problems in children with autism spectrum disorders: Prevalence and correlates in a large clinical sample," *Res. Autism Spectr. Disorders*, vol. 8, no. 9, pp. 1121–1133, 2014.
- [13] J. Harris, D. Allen, M. Cornick, A. Jefferson, and R. Mills, "Physical interventions: A policy framework," *Tizard Learn. Disability Rev.*, vol. 2, no. 3, pp. 41–42, Jul. 1997.
- [14] R. Coulter, "Understanding the visual symptoms of individuals with autism spectrum disorder (ASD)," *Optometry Vis. Develop.*, vol. 40, no. 3, pp. 1–12, 2009.
- [15] J. Six, O. Cornelis, and M. Leman, "TarsosDSP, a real-time audio processing framework in Java," in *Proc. AES Int. Conf.* 2014, pp. 240–246.
- [16] *Electroacoustics—Sound Level Meters—Part 1: Specifications*, Standard IEC 61672-1:2013, International Electrotechnical Commission, 2013.
- [17] *Acoustical Terminology*, Standard ANSI/ASA S1.1-2013, American National Standard Institute, 2013.
- [18] G. B. Arfken, H. J. Weber, and F. E. Harris, *Mathematical Methods for Physicists*, 7th ed. New York, NY, USA: Academic, 2013.
- [19] W. M. Carey and R. B. Evans, *Ocean Ambient Noise: Measurement and Theory*, 1st ed. New York, NY, USA: Springer-Verlag, 2011.
- [20] *Standard Specification for Electronic Thermometer for Intermittent Determination of Patient Temperature*, Standard ASTM E1112-00(2018), ASTM International, West Conshohocken, PA, 2018.
- [21] G. Kelly, "Body temperature variability (Part 1): A review of the history of body temperature and its variability due to site selection, biological rhythms, fitness, and aging," *Alternative Med. Rev.*, vol. 11, no. 4, pp. 211–278, 2006.
- [22] G. S. Kelly, "Body temperature variability (part 2): Masking influences of body temperature variability and a review of body temperature variability in disease," *Alternative Med. Rev.*, vol. 12, no. 1, pp. 49–62, 2007.
- [23] H. Sharma, "Heart rate extraction from PPG signals using variational mode decomposition," *Biocybern. Biomed. Eng.*, vol. 39, no. 1, pp. 75–86, Jan. 2019.
- [24] Classification Learner. (2020). *MathWorks*. Accessed: Aug. 16, 2020. [Online]. Available: <https://www.mathworks.com/help/stats/classificationlearner-app.html>
- [25] Neighborhood Component Analysis (NCA) Feature Selection. (2020). *MathWorks*. Accessed: Aug. 16, 2020. [Online]. Available: <https://es.mathworks.com/help/stats/neighborhood-component-analysis.html>



Automation, Miguel Hernandez University.

JOSE MARIA VICENTE-SAMPER (Graduate Student Member, IEEE) was born in Callosa de Segura, Spain. He received the M.Sc. degree in industrial engineering from Miguel Hernandez University, Elche, Spain, in 2017, where he is currently pursuing the Ph.D. degree in industrial and telecommunication technologies. Since 2015, he has been a Teaching and Research Assistant with the Neuroengineering Biomedical Group, Department of System Engineering and



ERNESTO ÁVILA-NAVARRO received the M.Sc. degree in telecommunication engineering from the Polytechnic University of Valencia, Valencia, Spain, in 1998, and the Ph.D. degree from Miguel Hernández University, Elche, Spain, in 2008. In 2000, he joined Miguel Hernández University, where he is currently an Associate Professor with the Department of Materials Science, Optics and Electronic Technology. He is currently the Vice-Dean of the School of Engineering of Elche.



and a Researcher of nBio Research Group. Since 2012, he has been the Director of the Master on Industrial Engineering.

JOSE MARIA SABATER-NAVARRO (Senior Member, IEEE) received the M.Sc. degree in industrial engineering from the Polytechnic University of Valencia, Valencia, Spain, in 1998, and the Ph.D. degree from Miguel Hernández University, Elche, Spain, in 2003. He received a Young Researchers Grant at the Chemical Institute (ITQ) CSIC-UPV, Polytechnic University of Valencia. He is currently a Full Professor with the Department of Systems Engineering and Automation,

Article

Intelligent Monitoring Platform to Evaluate the Overall State of People with Neurological Disorders

Jose Maria Vicente-Samper ^{1,*}, Ernesto Avila-Navarro ², Vicente Esteve ³ and Jose Maria Sabater-Navarro ¹

¹ Department of Systems Engineering and Automation, Miguel Hernández University of Elche, 03202 Elche, Spain; j.sabater@umh.es

² Department of Materials Science, Optics and Electronic Technology, Miguel Hernández University of Elche, 03202 Elche, Spain; eavila@umh.es

³ Department of Software and Computing Systems, University of Alicante, 03690 San Vicente del Raspeig, Spain; vesteve@ua.es

* Correspondence: jose.vicentes@umh.es

Abstract: The percentage of people around the world who are living with some kind of disability or disorder has increased in recent years and continues to rise due to the aging of the population and the increase in chronic health disorders. People with disabilities find problems in performing some of the activities of daily life, such as working, attending school, or participating in social and recreational events. Neurological disorders such as epilepsy, learning disabilities, autism spectrum disorder, or Alzheimer's, are among the main diseases that affect a large number of this population. However, thanks to the assistive technologies (AT), these people can improve their performance in some of the obstacles presented by their disorders. This paper presents a new system that aims to help people with neurological disorders providing useful information about their pathologies. This novelty system consists of a platform where the physiological and environmental data acquisition, the feature engineering, and the machine learning algorithms are combined to generate custom predictive models that help the user. Finally, to demonstrate the use of the system and the working methodology employed in the platform, a simple example case is presented. This example case carries out an experimentation that presents a user without neurological problems that shows the versatility of the platform and validates that it is possible to get useful information that can feed an intelligent algorithm.

check for
updates

Citation: Vicente-Samper, J.M.; Avila-Navarro, E.; Esteve, V.; Sabater-Navarro, J.M. Intelligent Monitoring Platform to Evaluate the Overall State of People with Neurological Disorders. *Appl. Sci.* **2021**, *11*, 2789. <https://doi.org/10.3390/app11062789>

Academic Editor: Juan Antonio Corrales Ramon

Received: 24 February 2021

Accepted: 17 March 2021

Published: 20 March 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/>).

Keywords: sensors; electronic platform; machine learning; wearables

1. Introduction

About one billion people live with some kind of disability. This corresponds to around 15% of the world's population [1]. The rate of disability is increasing, among other things due to the growth in the average age of the population and the increase in chronic health disorders. Lower income countries have a higher prevalence than higher income countries. Poor people have less resources to access treatment.

Half of people with disabilities cannot afford necessary medical care, compared to one third of non-disabled people who cannot afford it. People with disabilities have more than twice the probability of finding inadequate health care providers techniques, up to four times as likely to report improper treatment, and nearly three times as likely to be denied medical care [1].

Children with disabilities or disorders have a lower probability of attending school and receiving an adequate education. The probability of finding a job for a disabled person is also lower. Global employment data show that the employment rate for people with disabilities is 53% for men and 20% for women, while for people without disabilities it is 65% and 30% [1]. Therefore, people with disabilities are more vulnerable to poverty. They have worse living conditions due to the additional costs of their special needs (specialized

medical care, assistive devices, or people for supporting them). As a result, people with disabilities are generally poorer than people without disabilities who have similar incomes.

Neurological disorders are diseases that affect the central and peripheral nervous system, i.e., the brain, the nerves that are found in the human body, and the spinal cord. Millions of people worldwide suffer from neurological disorders. For example, more than 6 million people die each year from strokes, more than 50 million people around the world have epilepsy, and 7.7 million cases per year are diagnosed with Alzheimer's disease, which is the most common cause of dementia [2]. The specific causes of neurological problems vary, but they may include genetic disorders, congenital anomalies or disorders, infections, lifestyle or environmental health problems, brain injuries, spinal cord injuries, or nerve injuries [3].

On the other hand, neurological disabilities include a wide range of disorders, such as epilepsy, learning disabilities, neuromuscular disorders, autism spectrum disorder, attention deficit disorder, brain tumors and cerebral palsy, among many others. Some neurological pathologies are cognitive, and they appear before birth. Other neurological disorders may be caused by tumors, degeneration, trauma, infection, or structural defects. Regardless of the cause, all neurological disabilities are the result of damage to the nervous system [3]. The need for technological solutions that help people who are affected by these pathologies becomes evident.

Assistive technologies (AT) are devices or systems that can be used to help a person with a disability or disorder to perform daily life activities. The AT can help to improve the functional independence and thus, facilitate the daily living tasks through the use of aids that help a person to travel, to communicate with others, to learn, to work, and to participate in social and recreational activities [4]. AT devices can range from a simple and with low technology designs such as a crutch, to complex systems that speak for the user, automatic opening doors systems or to brain-wave recognition units for interface management [5].

Some of these assistive devices try to manage the associated problems of neurological disorders and facilitate the daily life of both the people who suffer from them and the family or support members who help them throughout their lives. An example is the Embrace device from Empatica [6]. It is a wrist-worn wearable device that monitors the user to detect possible convulsive seizures and alert caregivers. Another example of a monitoring device is the PdMonitor[®] from PD Neurotechnology [7]. It is a set of wearable monitoring devices, in this case for people with Parkinson's disorder. The device tracks, records, and processes a variety of symptoms, often present in this disease. A third example is the Monarch eTNS[®] System from NeuroSigma [8]. It is the first device approved by the U.S. Food and Drug Administration (FDA) for the treatment of the Attention Deficit disorder in children (ADHD). The device sends a low-level electrical pulse through a wire to a small patch adhered to the patient's forehead. The therapeutic pulses stimulate the branches of the trigeminal nerve, which activates the neural pathway to other parts of the brain thought to be involved in ADHD. Many research works for the development of new assistive devices can also be found. For example, the work of Cesareo et al. (2020) presents a system for monitoring the breathing rate in people with muscular dystrophy [9]. The system consists of a set of inertial measurement units integrated in wearable devices to control the long-term breathing pattern. Another work in progress is Floodlight Open, developed by the Hoffmann-La Roche company [10]. This is a study that aims to monitor the multiple sclerosis (MS) symptoms using a smartphone, through simple tasks specifically designed to assess the effects of MS.

There are other assistive devices that could be defined as intelligent platforms. These modular systems, in addition to monitoring the user and providing information about the user's condition, incorporate some type of intelligence in the form of decision algorithms or new machine learning methods that improve more traditional systems. For example, an intelligent tool for assisting people with Alzheimer's disease is presented in [11]. The system helps to monitor the user's health, control medication or locate the user

when they become disoriented, among other things. The system is composed by multiple devices that monitor the user, records their position, and control medication and objects that may be important. Through a mobile application, the user and caregivers have access to information and receive alerts. Another idea is presented in [12]. It proposed using wearable monitoring devices together with computational intelligence to diagnose and monitor people with Parkinson's disease. The assessment of Parkinson's Disease motor disabilities is based on neurological examination during patient's visits to the clinic and home diaries that the patient or the caregiver keeps. However, the short-time examination may not reveal important information. To overcome these limitations and difficulties, the ambulatory monitoring systems can improve this evaluation. Applying machine learning algorithms to these platforms allows to obtain intelligent systems for assistance. For example, Casalino et al. (2018) [13] present a system for real-time monitoring of cardiovascular problems using video images and fuzzy inference rules. The proposed system is composed of a transparent mirror with a camera that detects the user's face. The frames are processed using photoplethysmography in order to estimate different physiological parameters of the user. The estimated parameters are used to predict a risk of cardiovascular disease through fuzzy inference rules. Another system that employs the use of monitoring devices and machine learning algorithms is [14]. The authors present a gait-assistive system using a neural network. The system is composed of devices that monitor the user's movement during gait and stimulate the muscle nerves using electrical stimulation through electrodes. After a data collection phase, a model based on recurrent neural networks is trained. The model will be in charge of predicting the user's movement during gait and controlling the stimulation signal.

The purpose of this work is to present a full platform for the development of custom predictive models that help people with neurological disorders. Figure 1 sketches the concept of this work. The main challenges that this work faces are the signal acquisitions from the user and the environment, the signal processing, the dataset generation with feature engineering, and to train and optimize a predictive model. The aim is to use the generated model to help the user to manage their pathologies; therefore, the model will become an AT in his daily life. Unlike other works where the system is focused on a specific pathology or the algorithms used are optimized for a specific application, the proposed system is intended to be used for multiple pathologies and applications. The platform is presented in a generic way, where each of the stages can be adapted in order to obtain a different predictive model. This model will be personalized for the user and the desired application. Thus, to illustrate the versatility of the platform and to show the working methodology, a system validation experimentation is performed.

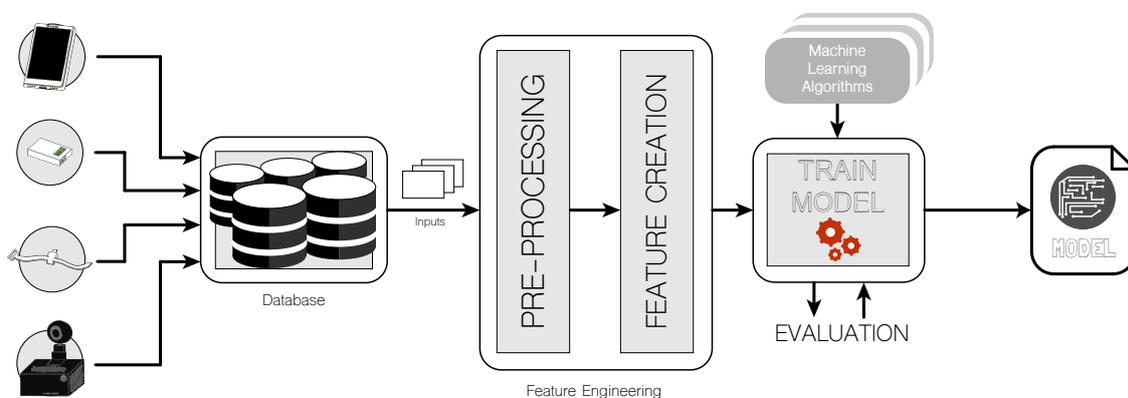


Figure 1. General concept of the proposed platform.

This paper is organized as follows. In the materials and methods section, the description of the different parts that make up the platform is presented. First, the acquisition system composed by four modular electronic devices. Then, Sections 2.2 and 2.3 describe the characteristics of the database and the feature engineering before training the model,

respectively. Section 2.4 shows the steps to follow towards generating predictive models using machine learning (ML) algorithms. In Section 2.5, a use case of the platform is presented; it is intended to generate a prediction model for people concentration in the workstation. Section 3 shows the results of the use case with data extracted from the generated model and its training. Finally, in Sections 4 and 5 the obtained results are discussed and the conclusions of the paper are outlined.

2. Materials and Methods

This section presents a platform for the generation of predictive models for people with neurological disorders (Figure 1). These models, customized for each user, intend to provide information about the pathology of the user and to help them manage it in a more controlled way. The generated information can also be used as input or as feedback for other assistive technologies. First, the different parts that make up the platform are described. Each of the stages can be adapted to the special conditions of the user and the final objective of the application to be developed. To conclude the section, an example of the use of the platform is described to show the workflow of the system.

2.1. Data Acquisition System

The first stage of the platform is the data acquisition system. This system is responsible for obtaining information from the user and from the surrounding environment. It has been developed with a modular architecture that allows adjusting the use of the devices according to the special characteristics of each user and the application that is carried out. For example, it allows the sensors to be restructured in the event that one of the devices is no longer required. An example of this would be to integrate the sound sensor into the smartphone in situations where the video device is not used, or vice versa. The system consists of four electronic devices: a smartphone, a wrist wearable device, an environmental monitoring device, and a video sensor device.

2.1.1. Personal and Environmental Devices

The environmental and personal monitoring devices are responsible for measuring the environmental conditions and the user's physiological variables, respectively. The development of these devices, which are integrated within the presented platform in this work, along with a study of the different parameters measured by this data acquisition system is described in [15].

The environmental monitoring device provides information about the luminosity, the environmental temperature, the relative humidity, and the atmospheric pressure of the environment where the user is. It is a small electronic device, which could be a key ring.

The personal monitoring device is the one described in [15], which integrates the measurement of the heart rate and the body temperature of the user. To complement the device, a new sensor has been integrated. It is an Inertial Measurement Unit (IMU), which provides information about the motor activity performed by the user. The details of this sensor and its integration into the system are described in Section 2.1.2. This personal monitoring equipment consists of a small wearable wrist device. Its design has been slightly updated to integrate the new sensor, and its dimensions have been reduced with respect to the previous version, despite integrating a larger capacity battery that provides an autonomy of more than 20 h of use. In addition, it has been manufactured with soft and comfortable materials that provide ergonomics and facilitate its placement for users with special difficulties. Figure 2 shows a picture of the new design, where the device, completely covered with EVA foam, can be seen. This also allows the device to weigh only 5.90 g, including the foam cover.



Figure 2. New design of the personal monitoring device.

On the other hand, the management of these monitoring devices is done with a smartphone via an Android application. The application, also described in [15], also allows displaying information to the user or to the caregiver. The interface and the displayed information can be modified depending on the user and the corresponding application. Furthermore, as described in [15], the smartphone also acts as a sound sensor, capturing the entire human audible spectrum (between 20 Hz and 22 kHz).

2.1.2. Motor Activity Sensor

The motor activity (MA) of the user is a relevant parameter that provides useful information to the platform. For example, it allows to evaluate the health and wellness in users with neurodegenerative disorders that influence in the motor functionality [16]. This parameter allows to quantify the arm movements and provides data about the user's displacement. In addition, together with other parameters, it is possible to estimate the state of mind or measure stress levels of the user [17].

The sensor used for the measurement consists of an IMU placed in the personal monitoring device, which integrates 3-axis gyroscope, 3-axis accelerometer, and 3-axis magnetometer. As an example, Figure 3 shows a fragment of the obtained signals by the MA sensor in the X-axis during a test session.

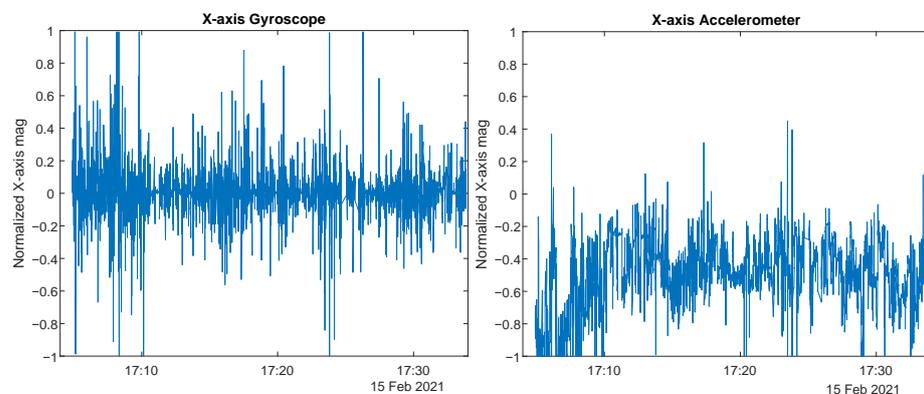


Figure 3. Example fragment of X-axis Gyroscope and Accelerometer signals recorded from the MA sensor during a test session.

The obtained data every sample by the sensor are organized in an array and stored in the corresponding collection within the database. The structure of a sample document for storing samples is shown below. The *date* and *dateString* parameters are the timestamp of the measurement in milliseconds and in character string, respectively. These parameters are included in every document in all data collections. The generated array with the measurement data is stored in the *motor* parameter. The *ObjectId* identifier is automatically set by the database when the document is uploaded.

```
{
  "_id" : ObjectId
  "date" : NumberLong
  "dateString" : "EEE MMM d HH:mm: ss z yyyy"
  "motor" : [gyrX , gyrY , gyrZ , accX , accY , accZ , magX , magY , magZ]
}
```

2.1.3. Video Device

The last device that makes up the data acquisition stage is the video device. The purpose of using this system is to obtain visual relevant information to the applications from the user's environment.

Some neurological disorders can cause difficulties in social interaction and therefore affect the mental wellbeing of the user [18]. Thus, one of the parameters measured by the video device is the number of people in the user's environment at any given time. In this way, the platform has information which together with other parameters allows to relate, for example, how social interaction can affect the user or whether an excessive presence of people around the user influences in the user's behavior [19].

On the other hand, regardless of the number of people around the user, some people with neurological disorders may feel overwhelmed if there is excessive activity around them, such as constant moving around or movements close to the user. In addition, these actions added to other stimuli, e.g., ambient noise, may be intensified [20]. Therefore, another parameter provided by the video device to the platform is the Optical Flow. The Optical Flow is the apparent motion pattern of objects in the image between two consecutive frames, caused by the displacement of the object or the camera. It is a 2-dimensional vector field where each vector represents a displacement vector indicating the movement of a point from its position in the first frame to its position in the second frame [21]. Consequently, if we keep the camera in a fixed position, the displacement that occurs in the image between frames will then be due only to the movement of the objects. In other words, we will have an estimate of how much movement occurs in the user's environment. The video device consists of an Nvidia Jetson Nanocompute card [22] and an Insta360 Air 360 degree camera [23]. The Jetson Nano has 128 *CUDA*[®] (Compute Unified Device Architecture) cores that encourage the execution of applications where computer vision and machine learning algorithms are used. The 360 degree camera provides the most complete possible picture of the user's environment. The system is mounted in a $118 \times 96 \times 60$ mm aluminum casing for portability between rooms. In addition, an improved cooling kit has been added to keep the temperature stable during use. An image of the video device is shown in Figure 4a.

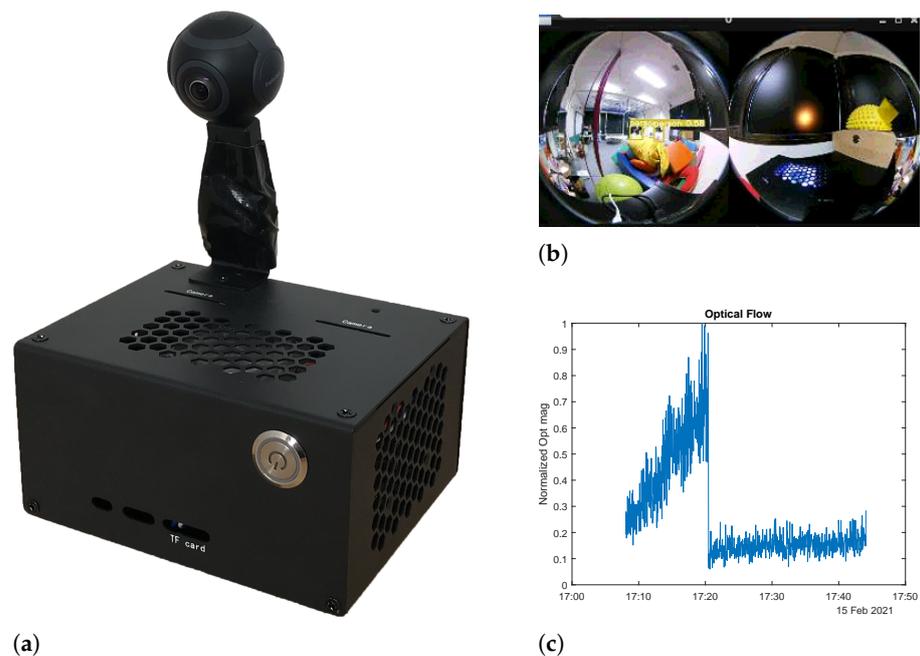


Figure 4. (a) Picture of the video device. (b) Screenshot of a people detection frame during a test session. (c) Example fragment of the optical flow signal recorded during a test session.

The first parameter introduced is the quantification of people in the user's environment. To do this, it is necessary to detect the people who are in the room at any given moment. This detection task is performed using a convolutional neural network (CNN) model. The algorithm used is YOLOv5 [24,25]. A pretrained model optimized for object detection is used. It has a high speed of execution doing inference and its size is contained. Figure 4b shows a screenshot of a frame where the detection of people during a test session is observed. It can be seen how the 360 degree camera captures the entire environment and the algorithm detects where the people are. The structure of a sample document for storing People Detection data is shown below. The *people* parameter stores the measured number of people.

```
{
  "_id" : ObjectId
  "date" : NumberLong
  "dateString" : "EEE MMM d HH:mm: ss z yyyy"
  "people" : NumberShort
}
```

On the other hand, there are different ways to measure the Optical Flow. In this case, a dense measurement of Optical Flow has been chosen, in which the displacement of all the points of the frame is calculated. To measure the Optical Flow of all the points in the image and to be able to quantify the movement that occurs in the user's environment, the method of Gunnar Farneback is used [26]. This algorithm is based on polynomial expansion and performs an estimation of the motion of two frames. Finally, the displacement modulus of both axes (X and Y) of the frame is stored. Figure 4c shows a fragment of the Optical Flow signal recorded during a test session. It can be observed how after a period of time the signal level is lower. This fact is due to a change of position by the people in the session to a place farther away from the camera, which results in a smaller change between frames and therefore a lower signal magnitude. The structure of a sample document for storing Optical Flow data is shown below. The *optical* parameter stores the estimated optical flow.

```
{
  "_id" : ObjectId
  "date" : NumberLong
  "dateString" : "EEE MMM d HH:mm: ss z yyyy"
  "optical" : NumberLong
}
```

2.2. Database

The next stage of the platform is in charge of storing the information obtained by the data acquisition system. The information must be organized in an efficient and secure way. Therefore, the database must have some characteristics that allow the platform to work properly and with minimum execution times. The main properties that must be met are listed below.

- It must allow the integration of multiple types of data, as well as change the architecture in which the information is stored if necessary.
- It must have continuous availability and scalability.
- It must support time-series. This requires less storage space and allows for faster query speed.
- It must perform continuous data updates that allow real-time analysis of the information.
- It must have strong access controls, data audits, and protect the data with encrypted controls. The information stored in the database is very valuable to the user and to the platform itself. Thus, the security standards must be met to ensure data anonymity and data access restriction.

The database used in the platform is a non-relational MongoDB database [27]. The information obtained by the data acquisition system is stored in documents within data collections, with a collection for each measured parameter. This allows new parameters to be integrated into the platform without the need to modify the storage architecture. An example of the collection storage structure is shown in Figure 5.

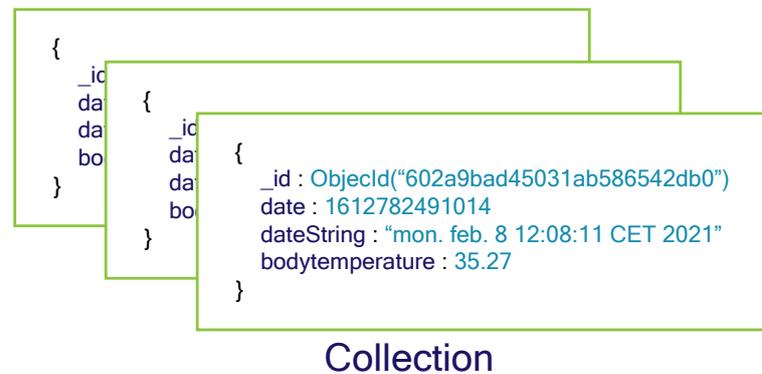


Figure 5. Example of database collection in the platform.

2.3. Feature Engineering

Feature engineering is the process of extracting attributes that improve the machine learning model from the raw information using data mining techniques [28]. The features must have an appropriate configuration. Therefore, these features are created from the previously acquired data, and their inputs are transformed and prepared for the machine learning (ML) model. Synthetic features that do not originally exist in the dataset are also created from the available information and they will allow the model to perform better.

The features have to comply with a series of properties in order to be suitable for use in the model. The attribute must be related to the objective of the application, i.e., it must be relevant in the output that our model is looking for. In addition, it must be certain that it will be possible to know the value of that feature at the time of the prediction; otherwise, the model will not work correctly. The value of the features must be numerical and must represent a magnitude. This is because, for example, a neural network is no more than a machine that performs arithmetic, trigonometric, and algebraic operations on the input variables [29]. Therefore, those features that are not numerical but are required to be used will have to be converted or encoded before introducing them into the model. Finally, it is also necessary to have enough examples of the features values to train the model correctly. The above rules are used to extract the appropriate features for the application and to generate a dataset that will be used to train and to validate the desired model. The transformations to be performed on the available signals in order to extract the attributes will depend on the final objective of the application. Therefore, once the problem to be faced has been defined, the signals must be analyzed and those that will be useful for the model must be selected. Subsequently, the necessary modifications will be made.

The final aim of this stage is to generate a suitable dataset to train the model. As mentioned above, this stage depends entirely on the information obtained from the model. Therefore, it is directly related to the result of the model training and could be placed in a parallel position to the next stage. In most of the times, it will be necessary to modify the dataset with new information or to change the existing features.

2.4. Training and Generation of a Custom Model

Using the generated feature dataset from the information collected by the data acquisition system, a customized model is trained for the user and the desired application. For this purpose, appropriate machine learning algorithms are used according to the specific application, i.e., it is particularized according to the information that will be predicted in the future. The training and evaluation process of the model is performed cyclically

until the optimal and sufficiently accurate behavior of the model is found. The dataset will be modified using the information obtained during training to improve the model accuracy. Finally, a validation of the model is performed with a part of the dataset reserved for testing. This allows checking the predictive behavior of the trained model, analyzing possible lines of improvement in the process, and verifying the accuracy for new inputs to the platform.

Once the training, validation, and testing processes of the model are completed, the trained model can be used to predict information from new inputs to the platform taken with the acquisition system. The model can be hosted on a client that runs continuously and can provide real-time feedback to the user.

The first step to be performed before starting the training is the split of the dataset into three parts. A diagram of this split is shown in Figure 6. The first fragment will be the training data (training set). The training set is the dataset used by the model to learn how to process the information. From these data, the model adjusts the parameters of the classifier or from the algorithm used in the model. Using the training set, different machine learning algorithms can be evaluated to generate the model, and the results obtained can be compared to obtain the most appropriate one for the application. The training set contains most of the data from the main dataset. The validation set is used to estimate how well the model has been trained. This can be done between periodic training cycles and when the training process has been completed. It is also used to estimate model properties, such as the error in a classifier or the precision and recall in binary models. Cross-validation is the most commonly used method for this task [30]. Finally, there is the test set. It is used only to evaluate the performance of the model after the training process has been completed. It can be considered as a mock production use of the model.

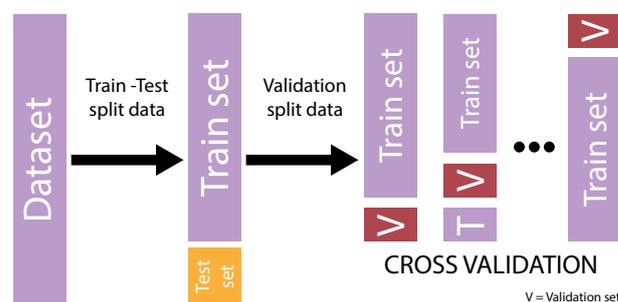


Figure 6. Workflow of dataset split and cross validation process.

2.5. Creation of a People Concentration Model in the Workstation

The system presented in this paper can be used for multiple pathologies and applications. The acquisition system and the database allow to easily adapt or integrate new sensors. The signal processing, the feature analysis, and the machine learning algorithms used to generate the model will also be defined according to the objective. To show the workflow of the platform, an experimentation to validate the system is performed. The test consist of generating a personalized model of the concentration of a person in two different workstations within the same research laboratory. One of the places is located at the entrance of the laboratory, next to the door. Any person who must access or leave the laboratory has to pass by this position, which we will call Position A. The second position (Position B) is located in an isolated room within the same laboratory.

The final goal of the model is to predict at which times the person is focused on the tasks being performed and at which times the concentration is reduced, for example, due to an interruption or stimuli around the workstation. This will provide information on which of the positions is the most suitable to work at. Although this application is not directly related to assisting people with neurological disorders, it is an example of the versatility that the system can offer as well as to show the working methodology of the platform. In addition, a similar model could also be proposed for a person with a neurological disorder so that it would be possible to analyze how the user adapts to a specific work

environment. The two possible situations are labeled as “*Focused*” and “*Distracted*”, and the output of the predictive model will be one of these two options.

First, it is necessary to define what will be considered as “*Focused*” and “*Distracted*”. For this example, a first supervised part has been proposed where data are collected from the person and the environment in both workstations performing a task that allows to quantify the person’s concentration on the task. This task consists of reading an entertainment book. The reading of technical or scientific documents, which a priori could be more related to a task to be developed in the person’s work, has been discarded, because the reading pace may not be constant due to the complexity of certain parts throughout the document. During this supervised period, the number of lines per minute read by the user is counted. In this way, a range is established in which the person is considered focused on the task. Below that range, the person is considered distracted. The supervised task is necessary to establish the user’s concentration level in a quantitative way. The model needs this information to learn in which situations the user is focused on the task.

Once the supervised stage is completed, the necessary information is available to generate the new model, always based on the previously established definition of concentration. The second part of the experimentation corresponds to the unsupervised collection of new data in both workstations. The user performs the usual tasks of his job. The new information collected will be used to estimate the concentration levels of the person in both workstations using the generated model with the supervised data.

For the supervised stage, a data acquisition period of 180 min has been established for each of the established positions (A and B), i.e., a total of 6 h. To make the supervised experimentation more user-friendly, the time has been divided into three one-hour periods, taken on consecutive days. Subsequently, for the unsupervised stage, a total of 8 h of data have been collected. For each of the positions, 4 h have been taken. In turn, these 4 h have been captured in 2-h periods on consecutive days.

The next step is to analyze the available signals and decide which data can provide relevant information to the model. As the experimentation is performed in a controlled environment, the weather conditions are kept constant over time at both workstations. Therefore, ambient temperature, relative humidity, and atmospheric pressure do not provide information to the model that helps to predict the concentration level and are discarded. Similarly, the use of the ambient luminosity can be discarded as the values also remain constant over time and of the same magnitude, both at position A and B. Finally, the use of the magnetometer signal from the MA sensor is also discarded because it is not necessary to know the user’s position. Thus, the heart rate and the body temperature signals of the user, the gyroscope and the accelerometer signals of the MA sensor, the ambient sound, and the signals of the video device (optical flow and people detection) would remain.

When the available signals to be used have been decided, a preprocessing is performed before generating the dataset. The different transformations applied to each of them are described below.

- **Sound:** The audio spectrum is available divided into frequency bands. For the desired model, the information isolated by frequencies is not needed. Thus, a feature that contains the accumulated energy value in all frequency bands is generated. We use Equation (1) for this purpose:

$$Sound_{total} = 10 \log \left(\sum_{i=1}^n 10^{\frac{Sound_i}{10}} \right) \quad (1)$$

- **Heart Rate:** The heart rate value is available in 6-s windows. As the photoplethysmography signal used to obtain the heart rate value is very sensitive to motion artifacts, the 75th percentile of the last 30 s is used as feature for the dataset.
- **Body Temperature:** The body temperature value does not require any special transformation. The obtained signal itself is used as a feature.

- **Gyroscope and Accelerometer:** The gyroscope and the accelerometer signals are available separately in the three axes (X, Y, and Z). For the desired model the divided information is not needed, so a feature is generated with the module of the three axes for the gyroscope signal and another one for the accelerometer signal.
- **Optical Flow and People Detection:** Both the Optical Flow signal and the quantification of people do not require any special transformation for the dataset. The signals obtained are used as features.

Finally, the signals of all the generated features are normalized, excluding the quantification of people. A fragment of these signals can be seen in the Appendix A in Figure A1. Once the features have been established and the different transformations have been carried out, the dataset is generated. For this purpose, a time vector is created where the time values of all the features are chronologically ordered together inside with an identifier that indicates the feature to which they belong. In addition, an index is assigned to each of the features indicating the last entry added to the dataset. Then, the time vector is browsed, adding to the dataset the values of the different features of the position indicated by each of its indexes. This merging generates an input in the dataset. Once the entire time vector has been browsed, the dataset is complete with all the information generated. To describe this process graphically, a schematic is shown in Figure 7.

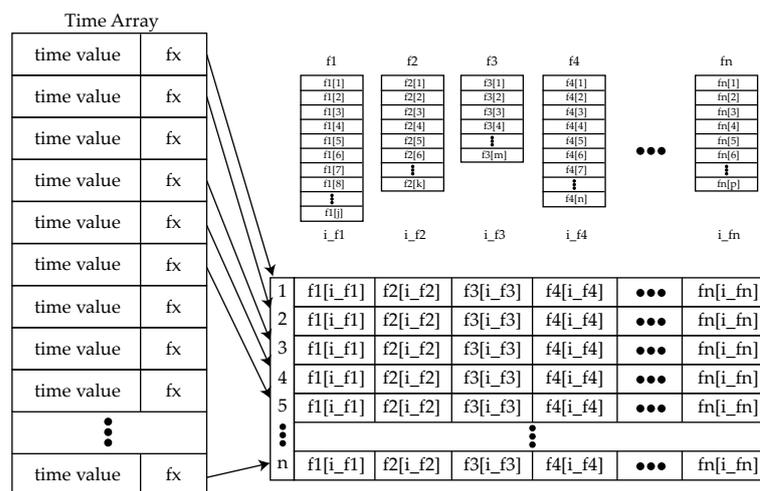


Figure 7. Diagram of the dataset generation process.

Using the described method, both datasets are generated for our model with the data collected in the experiment (supervised set and unsupervised set). Table 1 shows the distribution of both. Therefore, joining the records in both positions (A and B), we have a dataset for training and validation of the model with 17,135 entries, with 34.08% of entries labeled as “Distracted”.

Table 1. Datasets distribution.

Supervised Data				
	Position A		Position B	
Class	Records	Percentage	Records	Percentage
Focused	5354	62.18%	5942	69.71%
Distracted	3257	37.82%	2582	30.29%
Unsupervised Data				
	Position A		Position B	
Records	11350		11234	

For training and validation of the model, the dataset has been split (80–20%). Between different checked algorithms, a sequential neural network model has been selected due to its performance with the available dataset. The neural network architecture has also been adjusted from the simplest to obtain an adequate performance without increasing the inference time excessively. The selected neural network consists of the input layer, two hidden layers with 120 and 80 nodes with “*relu*” type activation function and the output layer with 2 nodes and “*softmax*” as activation function. A schematic of the model structure is shown in Figure 8. The parameters used for training the model are as follows.

```
{
  Optimizer = Adam,
  Loss function = Sparse Categorical Crossentropy,
  Batch size = 10,
  Numer of epochs = 500
}
```

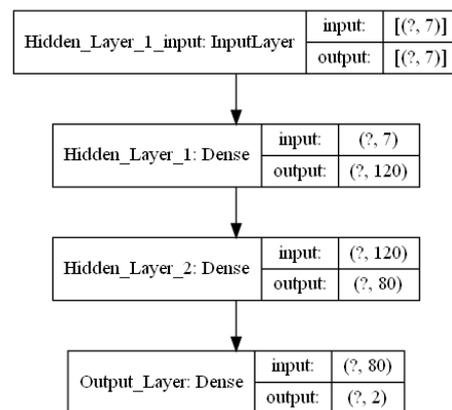


Figure 8. Architecture of the model.

3. Results

It should not be forgotten that the final aim of the experimentation is to generate a model of the concentration of a person in two different workstations within the same laboratory. This section attempts to present the results obtained from both the training of the model and the experimentation itself.

The obtained results of the model training are summarized in the Table 2. The Receiver Operating Characteristic (ROC) curve and its respective Area Under Curve (AUC) are included in Figure 9. The performance of the model is very fine. The model is able to recognize which dataset inputs have been defined as “*Focused*” and “*Distracted*” with high accuracy.

Table 2. Report of the model performance.

Class	Precision	Recall	F1-Score
Focused	0.97	0.95	0.96
Distracted	0.93	0.96	0.94
Average/Total	0.95	0.95	0.95
Accuracy	95.26%		

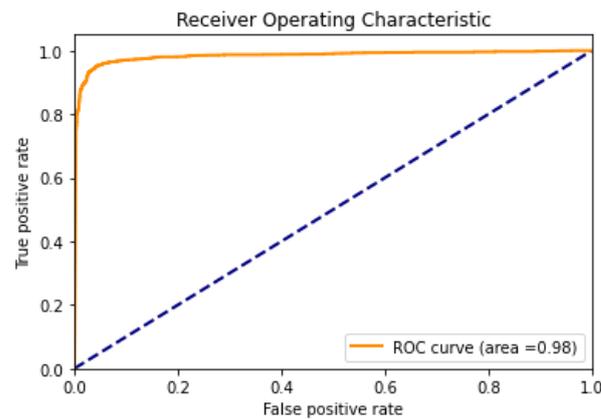


Figure 9. Receiver Operating Characteristic (ROC) curve of the model training result.

Once the model has been generated and evaluated its performance, the unsupervised dataset is used in order to identify each dataset input as a “*Focused*” or “*Distracted*” situation using the model. The results obtained are shown in Figure 10. A comparative graph between both positions (A and B) can be seen.

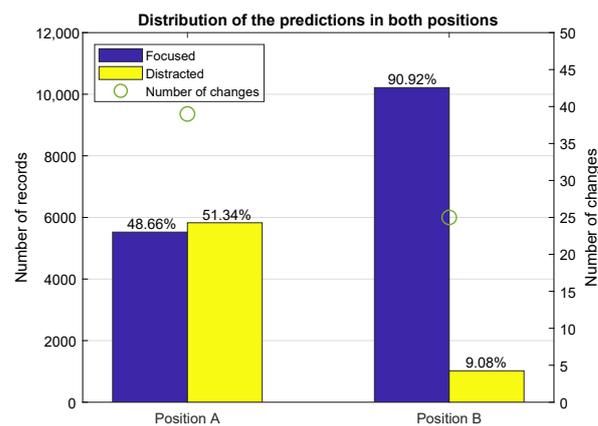


Figure 10. Obtained distribution of the predictions of the unsupervised data.

4. Discussion

A model with successful results has been trained only using seven generated features from all the integrated signals in the platform. As can be seen in Table 2, the error in the model evaluation is very low. The AUC is very close to 1 (Figure 9), which means that the obtained results in the evaluation are almost perfect.

Analyzing the generated predictions by the model from the unsupervised set (Figure 10), the total time of concentration in Position B is higher. There is a notable difference in the time that the user remains focused on his tasks in Position A (51.34%), with respect to Position B, where more than the 90% of the time has been identified as “*Focused*”. In addition, the concentration time has undergone a 50% more changes in the level of concentration in Position A (39) than in Position B (25). This implies that concentration periods are shorter between distractions. Therefore, it seems that as common sense would indicate, Position B is a better workstation.

Regarding the performance of the initial stages of the platform, the acquisition data system has allowed obtaining signals with good quality in all devices and the storage protocol has worked correctly. The analysis of the signals and the processing carried out to extract the features have been customized for the application that has been presented as an example of use. However, the platform presented in this work has demonstrated

high versatility when it comes to generating new information that can help people with neurological disorders.

5. Conclusions

This work aims to present an intelligent platform that could provide useful information about people with neurological pathologies as an assistive technology. The novelty of this work is the acquisition of physiological and environmental signals for the generation of predictive models using machine learning algorithms. Throughout the paper, the different stages that make up the system have been described. Finally, an example of the use of the platform is presented, which allows a more detailed description of each of the steps taken until the desired model is obtained. The proposed application in the experimentation does not have a direct relationship with the assistance to people with neurological disorders. However, it has made it possible to describe the work at each stage of the platform. In addition, the presented example could be transformed into a real case with a user with a neurological disorder. For example, the platform could be used to measure the user's level of adaptation to a particular job.

This paper attempts to show the versatility offered by the presented system. The modular design allows to integrate or adapt different sensors. The analysis and processing of the signals will be defined according to the objective for which the platform is to be used. Likewise, the machine learning algorithms used will depend on the model to be obtained. However, to generate a real predictive model that helps to manage problems arising from a neurological disorder, it is necessary to collect a much larger amount of information than the used for the example case. In addition, the feature engineering that must be developed to obtain the appropriate features for the model is also very complex. Therefore, the system has been presented in a generic way together with a simple example to show the workflow.

Currently, the system is in use for the development of a personalized models of people with ASD, one for each user. Every model should predict behavioral changes in the user due to environmental stimuli, caused by a sensory processing problem derived from their pathology. Data collection is being developed in a clinical setting. Another possible use could be to obtain information about the stress level of a person with reduced mobility. The information provided by the platform could be used to modify the user's posture, alert the caregiver, etc. Different applications could also be to have an intelligent feedback system during a session of rehabilitation activities, or to be used in Sleep Disorders Units.

Author Contributions: Conceptualization, J.M.V.-S. and J.M.S.-N.; methodology, J.M.V.-S. and J.M.S.-N.; software, J.M.V.-S.; validation, J.M.S.-N., E.A.-N., and J.M.V.-S.; formal analysis, J.M.V.-S., V.E., and E.A.-N.; investigation, J.M.V.-S.; resources, J.M.V.-S. and E.A.-N.; data curation, J.M.V.-S.; writing—original draft preparation, J.M.V.-S.; writing—review and editing, J.M.S.-N., E.A.-N., V.E., and J.M.V.-S.; visualization, J.M.V.-S.; supervision, J.M.S.-N., E.A.-N., and J.M.V.-S.; project administration, J.M.S.-N. and J.M.V.-S.; funding acquisition, J.M.S.-N. and E.A.-N. All authors have read and agreed to the published version of the manuscript.

Funding: This work was partially funded by Spanish Research State Agency and European Regional Development Fund through "Race" Project (PID2019-111023RB-C32). The work of J.M.V.-S. is supported by the Conselleria d'Educació, Investigació, Cultura i Esport (GVA) through FD-GENT/2018/015 project.

Institutional Review Board Statement: Not applicable.

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

Appendix A

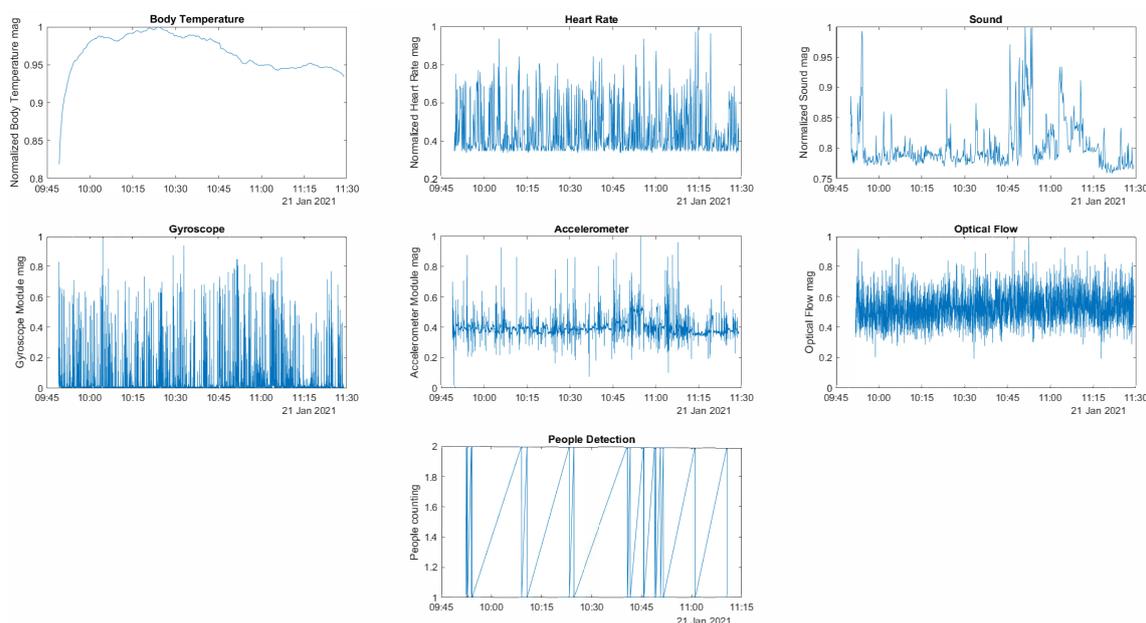


Figure A1. Fragment of the selected signals as features during the experimentation.

References

- World Health Organization. Ten Facts on Disability. 2017. Available online: <https://www.who.int/features/factfiles/disability/en/> (accessed on 5 February 2021).
- World Health Organization. Mental Health: Neurological Disorders. 2016. Available online: <https://www.who.int/features/qa/55/en/> (accessed on 5 February 2021).
- Montana Department of Public Health & Human Services. Neurological Disorders. Available online: <https://dphhs.mt.gov/schoolhealth/chronichealth/neurologicaldisorders> (accessed on 5 February 2021).
- Centers for Disease Control and Prevention. People with Disabilities. 2020. Available online: <https://www.cdc.gov/ncbddd/disabilityandhealth/people.html> (accessed on 5 February 2021).
- Cook, A.M.; Polgar, J.M. Chapter 2—Technologies that Assist People Who Have Disabilities In *Assistive Technologies*, 4th ed.; Cook, A.M., Polgar, J.M., Eds.; Elsevier: Maryland Heights, MO, USA, 2015; pp. 16–39. [\[CrossRef\]](#)
- Empatica. Embrace 2—Smarter Epilepsy Management. 2020. Available online: <https://www.empatica.com/en-eu/embrace2/> (accessed on 6 February 2021).
- PD Neurotechnology. PD Monitor Solution. 2021. Available online: <https://www.pdneurotechnology.com/pd-monitor-solution/product/> (accessed on 6 February 2021).
- NeuroSigma. Monarch eTNS System[®] for Pediatric ADHD. 2020. Available online: <https://www.monarch-etns.com/> (accessed on 6 February 2021).
- Cesareo, A.; Nido, S.A.; Biffi, E.; Gandossini, S.; D’angelo, M.G.; Aliverti, A. A wearable device for breathing frequency monitoring: A pilot study on patients with muscular dystrophy. *Sensors* **2020**, *20*, 5346. [\[CrossRef\]](#) [\[PubMed\]](#)
- Hoffmann-La Roche. Floodlight Open. Understanding MS Together. 2021. Available online: <https://floodlightopen.com/> (accessed on 6 February 2021).
- Omar, K.S.; Rabbi, F.; Anjum, A.; Oannahary, T.; Karim Rizvi, R.; Shahrin, D.; Anannya, T.T.; Nasreen Tumpa, S.; Karim, M.; Nazrul Islam, M. An Intelligent Assistive Tool for Alzheimer’s Patient. In Proceedings of the 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT), East West University, Dhaka, Bangladesh, 3–5 May 2019. [\[CrossRef\]](#)
- Romero, L.E.; Chatterjee, P.; Armentano, R.L. An IoT approach for integration of computational intelligence and wearable sensors for Parkinson’s disease diagnosis and monitoring. *Health Technol.* **2016**, *6*, 167–172. [\[CrossRef\]](#)
- Casalino, G.; Castellano, G.; Pasquadibisceglie, V.; Zaza, G. Contact-less real-time monitoring of cardiovascular risk using video imaging and fuzzy inference rules. *Information* **2018**, *10*, 9. [\[CrossRef\]](#)
- Tang, S.Y.; Hoang, N.S.; Chui, C.K.; Lim, J.H.; Chua, M.C.H. Development of Wearable Gait Assistive Device Using Recurrent Neural Network. In Proceedings of the 2019 IEEE/SICE International Symposium on System Integration (SII), Paris, France, 14–16 January 2019; pp. 626–631. [\[CrossRef\]](#)
- Vicente-Samper, J.M.; Ávila-Navarro, E.; Sabater-Navarro, J.M. Data Acquisition Devices Towards a System for Monitoring Sensory Processing Disorders. *IEEE Access* **2020**, *8*, 183596–183605. [\[CrossRef\]](#)

16. Prathivadi, Y.; Wu, J.; Bennett, T.R.; Jafari, R. Robust activity recognition using wearable IMU sensors. In Proceedings of the IEEE Sensors, Valencia, Spain, 2–5 November 2014; pp. 486–489. [CrossRef]
17. Can, Y.S.; Arnrich, B.; Ersoy, C. Stress detection in daily life scenarios using smart phones and wearable sensors: A survey. *J. Biomed. Inform.* **2019**, *92*, 103139. [CrossRef] [PubMed]
18. Henry, J.D.; Von Hippel, W.; Molenberghs, P.; Lee, T.; Sachdev, P.S. Clinical assessment of social cognitive function in neurological disorders. *Nat. Rev. Neurol.* **2016**, *12*, 28–39. [CrossRef] [PubMed]
19. Altogether Autism. A Shift in Perspective: Empathy and Autism. 2021. Available online: <https://www.altogetherautism.org.nz/a-shift-in-perspective-empathy-and-autism/> (accessed on 17 February 2021).
20. Clark, C.; Crumpler, C.; Notley, H. Evidence for environmental noise effects on health for the United Kingdom policy context: A systematic review of the effects of environmental noise on mental health, wellbeing, quality of life, cancer, dementia, birth, reproductive outcomes, and cognition. *Int. J. Environ. Res. Public Health* **2020**, *17*, 393. [CrossRef] [PubMed]
21. OpenCV. OpenCV: Optical FLOW. 2021. Available online: https://docs.opencv.org/3.4/d4/dee/tutorial_optical_flow.html (accessed on 17 February 2021).
22. Nvidia. Jetson Nano. 2021. Available online: <https://developer.nvidia.com/embedded/jetson-nano> (accessed on 17 February 2021).
23. Insta360. Insta360 Air. 2021. Available online: <https://www.insta360.com/es/product/insta360-air> (accessed on 17 February 2021).
24. Bochkovskiy, A.; Wang, C.Y.; Liao, H.Y.M. YOLOv4: Optimal Speed and Accuracy of Object Detection. *arXiv* **2020**, arXiv:2004.10934.
25. Jocher, G.; Stoken, A.; Borovec, J.; NanoCode012; ChristopherSTAN; Changyu, L.; Laughing; tkianai; yxNONG; Hogan, A.; et al. ultralytics/yolov5: v4.0 - nn.SiLU() activations, Weights & Biases logging, PyTorch Hub integration. *Zenodo* **2021**. [CrossRef]
26. Farneb, G. Two-Frame Motion Estimation Based on. *Lect. Notes Comput. Sci.* **2003**, *2749*, 363–370.
27. MongoDB. The Most Popular Database for Modern Apps. 2021. Available online: <https://www.mongodb.com> (accessed on 15 February 2021).
28. Khurana, U.; Turaga, D.; Samulowitz, H.; Parthasarathy, S. Cognito: Automated Feature Engineering for Supervised Learning. In Proceedings of the IEEE International Conference on Data Mining Workshops (ICDMW), Barcelona, Spain, 12–15 December 2016; pp. 1304–1307. [CrossRef]
29. Wang, S.C. Artificial neural network (ANNs). In *Interdisciplinary Computing in Java Programming*; The Springer International Series in Engineering and Computer Science; Springer: Boston, MA, USA, 2003; Volume 743. [CrossRef]
30. Browne, M.W. Cross-Validation Methods. *J. Math. Psychol.* **2000**, *44*, 108–132. [CrossRef] [PubMed]

BIBLIOGRAFÍA

- Accordino, R. E.; Kidd, C.; Politte, L. C.; Henry, C. A. y McDougale, C. J. (2016), «Psychopharmacological interventions in autism spectrum disorder», *Expert Opinion on Pharmacotherapy* **17**(7), págs. 937-952, DOI: [10.1517/14656566.2016.1154536](https://doi.org/10.1517/14656566.2016.1154536), eprint: <https://doi.org/10.1517/14656566.2016.1154536> (vid. pág. 16).
- Acoustical Terminology* (2013), inf. téc., Standard ANSI/ASA S1.1-2013, American National Standard Institute, (vid. pág. 60).
- Allen, J. (2007), «Photoplethysmography and its application in clinical physiological measurement», *Physiological Measurement* **28**(3), R1, DOI: [10.1088/0967-3334/28/3/R01](https://doi.org/10.1088/0967-3334/28/3/R01) (vid. pág. 31).
- Anderson, D. K.; Liang, J. W. y Lord, C. (2014), «Predicting young adult outcome among more and less cognitively able individuals with autism spectrum disorders», *Journal of Child Psychology and Psychiatry and Allied Disciplines* **55**(5), págs. 485-494, DOI: [10.1111/jcpp.12178](https://doi.org/10.1111/jcpp.12178) (vid. pág. 3).
- Anderson, R. R. y Parrish, J. A. (1981), «The Optics of Human Skin», *Journal of Investigative Dermatology* **77**(1), págs. 13-19, DOI: <https://doi.org/10.1111/1523-1747.ep12479191> (vid. pág. 30).
- Apple (2020), *Uso del Apple Watch para la detección de arritmias cardiacas*, Retrieved from https://www.apple.com/es/healthcare/docs/site/Apple_Watch_Arrhythmia_Detection.pdf (vid. pág. 17).
- Apple (2021), *Apple Watch Series 6*, Retrieved from <https://www.apple.com/es/apple-watch-series-6/> (vid. pág. 17).
- Arana, I. (2019), *La inquietante apuesta china por el reconocimiento facial*, Retrieved from <https://www.lavanguardia.com/tecnologia/20190518/462270404745/reconocimiento-facial-china-derechos-humanos.html> (vid. pág. 20).
- Arfken, G. B.; Weber, H. J. y Harris, F. E., eds. (2013), Seventh Edition, Boston: Academic Press, págs. xi-xiii, ISBN: 978-0-12-384654-9, DOI: <https://doi.org/10.1016/B978-0-12-384654-9.00032-3> (vid. pág. 61).
- Armstrong, B.; Sera, F.; Vicedo-Cabrera, A. M.; Abrutzky, R.; Åström, D. O.; Bell, M. L.; Chen, B.-Y.; Sousa Zanotti Stagliorio Coelho, M. de; Correa, P. M.; Dang, T. N.; Diaz, M. H.; Dung, D. V.; Forsberg, B.; Goodman, P.; Guo, Y.-L. L.; Guo, Y.; Hashizume,

- M.; Honda, Y.; Indermitte, E.; Íñiguez, C.; Kan, H.; Kim, H.; Kyselý, J.; Lavigne, E.; Michelozzi, P.; Orru, H.; Ortega, N. V.; Pascal, M.; Ragetti, M. S.; Saldiva, P. H. N.; Schwartz, J.; Scortichini, M.; Seposo, X.; Tobias, A.; Tong, S.; Urban, A.; Cruz Valencia, C. D. la; Zanobetti, A.; Zeka, A. y Gasparrini, A. (2019), «The Role of Humidity in Associations of High Temperature with Mortality: A Multicountry, Multicity Study», *Environmental Health Perspectives* **127**(9), pág. 097007, DOI: [10.1289/EHP5430](https://doi.org/10.1289/EHP5430) (vid. pág. 45).
- Association, W. M. (2013), «Declaration of Helsinki, Ethical Principles for Scientific Requirements and Research Protocols», *Bulletin of the World Health Organization* **79**(4), pág. 373, Retrieved from <https://www.wma.net/policies-post/wma-declaration-of-helsinki-ethical-principles-for-medical-research-involving-human-subjects/> (vid. pág. 102).
- Autism, A. (2021), *A shift in perspective: empathy and autism*, Retrieved from <https://www.altogetherautism.org.nz/a-shift-in-perspective-empathy-and-autism/> (vid. pág. 55).
- Ayres, A. J. (1972), *Sensory integration and learning disorders*, Western Psychological Services (vid. pág. 5).
- Baker, A. E.; Lane, A.; Angley, M. T. y Young, R. L. (2008), «The relationship between sensory processing patterns and behavioural responsiveness in autistic disorder: A pilot study», *Journal of Autism and Developmental Disorders* **38**(5), págs. 867-875, DOI: [10.1007/s10803-007-0459-0](https://doi.org/10.1007/s10803-007-0459-0) (vid. págs. 5, 7).
- Bejnordi, B. E.; Veta, M.; Van Diest, P. J.; Van Ginneken, B.; Karssemeijer, N.; Litjens, G.; Van Der Laak, J. A.; Hermsen, M.; Manson, Q. F.; Balkenhol, M.; Geessink, O.; Stathonikos, N.; Van Dijk, M. C.; Bult, P.; Beca, F.; Beck, A. H.; Wang, D.; Khosla, A.; Gargeya, R.; Irshad, H.; Zhong, A.; Dou, Q.; Li, Q.; Chen, H.; Lin, H. J.; Heng, P. A.; Haß, C.; Bruni, E.; Wong, Q.; Halici, U.; Öner, M. Ü.; Cetin-Atalay, R.; Berseth, M.; Khvatkov, V.; Vylegzhanin, A.; Kraus, O.; Shaban, M.; Rajpoot, N.; Awan, R.; Sirinukunwattana, K.; Qaiser, T.; Tsang, Y. W.; Tellez, D.; Annuscheit, J.; Hufnagl, P.; Valkonen, M.; Kartasalo, K.; Latonen, L.; Ruusuvoori, P.; Liimatainen, K.; Albarqouni, S.; Mungal, B.; George, A.; Demirci, S.; Navab, N.; Watanabe, S.; Seno, S.; Takenaka, Y.; Matsuda, H.; Phoulady, H. A.; Kovalev, V.; Kalinovsky, A.; Liauchuk, V.; Bueno, G.; Fernandez-Carrobles, M. M.; Serrano, I.; Deniz, O.; Racoceanu, D. y Venâncio, R. (2017), «Diagnostic assessment of deep learning algorithms for detection of lymph node metastases in women with breast cancer», *JAMA - Journal of the American Medical Association* **318**(22), págs. 2199-2210, DOI: [10.1001/jama.2017.14585](https://doi.org/10.1001/jama.2017.14585) (vid. pág. 22).

- Bent, B.; Goldstein, B. A.; Kibbe, W. A. y Dunn, J. P. (2020), «Investigating sources of inaccuracy in wearable optical heart rate sensors», *npj Digital Medicine* 3(1), págs. 1-9, DOI: [10.1038/s41746-020-0226-6](https://doi.org/10.1038/s41746-020-0226-6) (vid. pág. 124).
- Benzinger, T. H. (1969), «Heat regulation: homeostasis of central temperature in man», *Physiological Reviews* 49(4), págs. 671-759, DOI: [10.1152/physrev.1969.49.4.671](https://doi.org/10.1152/physrev.1969.49.4.671) (vid. pág. 26).
- Biswas, D.; Everson, L.; Liu, M.; Panwar, M.; Verhoef, B. E.; Patki, S.; Kim, C. H.; Acharyya, A.; Van Hoof, C.; Konijnenburg, M. y Van Helleputte, N. (2019), «CorNET: Deep Learning Framework for PPG-Based Heart Rate Estimation and Biometric Identification in Ambulant Environment», *IEEE Transactions on Biomedical Circuits and Systems* 13(2), págs. 282-291, DOI: [10.1109/TBCAS.2019.2892297](https://doi.org/10.1109/TBCAS.2019.2892297) (vid. pág. 127).
- Blake-Wilson, S.; Nystrom, M.; Hopwood, D.; Mikkelsen, J. y Wright, T. (2003), «Transport layer security (TLS) extensions», *Request for Comments* 3546 (vid. pág. 66).
- Bochkovskiy, A.; Wang, C. Y. y Liao, H. Y. M. (2020), «YOLOv4: Optimal Speed and Accuracy of Object Detection», *arXiv*, eprint: [2004.10934](https://arxiv.org/abs/2004.10934) (vid. pág. 56).
- Bosch (2020), *BMP280 Digital Pressure Sensor*, Retrieved from <https://www.bosch-sensortec.com/media/boschsensortec/downloads/datasheets/bst-bmp280-ds001.pdf> (vid. pág. 47).
- Bradski, G. (2000), «The OpenCV Library», *Dr. Dobb's Journal of Software Tools* (vid. pág. 57).
- Brasil, S.; Pascoal, C.; Francisco, R.; Reis Ferreira, V. dos; A. Videira, P. y Valadão, G. (2019), «Artificial Intelligence (AI) in Rare Diseases: Is the Future Brighter?», *Genes* 10(12), DOI: [10.3390/genes10120978](https://doi.org/10.3390/genes10120978) (vid. pág. 21).
- Browne, M. W. (2000), «Cross-Validation Methods», 132, págs. 108-132 (vid. pág. 99).
- Campbell, I. (2008), «Body temperature and its regulation», *Anaesthesia & Intensive Care Medicine* 9(6), págs. 259-263, DOI: <https://doi.org/10.1016/j.mpaic.2008.04.009> (vid. pág. 27).
- Can, Y. S.; Arnrich, B. y Ersoy, C. (2019), «Stress detection in daily life scenarios using smart phones and wearable sensors: A survey», *Journal of Biomedical Informatics* 92(February), pág. 103139, DOI: [10.1016/j.jbi.2019.103139](https://doi.org/10.1016/j.jbi.2019.103139) (vid. pág. 33).
- Carson, V.; Ridgers, N. D.; Howard, B. J.; Winkler, E. A.; Healy, G. N.; Owen, N.; Dunstan, D. W. y Salmon, J. (2013), «Light-Intensity Physical Activity and Cardiometabolic Biomarkers in US Adolescents», *PLoS ONE* 8(8), DOI: [10.1371/journal.pone.0071417](https://doi.org/10.1371/journal.pone.0071417) (vid. pág. 33).
- Casalino, G.; Castellano, G.; Pasquadibisceglie, V. y Zaza, G. (2019), «Contact-less real-time monitoring of cardiovascular risk using video imaging and fuzzy inference

- rules», *Information (Switzerland)* **10**(1), págs. 1-17, DOI: [10.3390/info10010009](https://doi.org/10.3390/info10010009) (vid. pág. 22).
- Cesareo, A.; Nido, S. A.; Biffi, E.; Gandossini, S.; D'angelo, M. G. y Aliverti, A. (2020), «A wearable device for breathing frequency monitoring: A pilot study on patients with muscular dystrophy», *Sensors* **20**(18), págs. 1-19, DOI: [10.3390/s20185346](https://doi.org/10.3390/s20185346) (vid. pág. 19).
- Challoner, A. V. y Ramsay, C. A. (1974), «A photoelectric plethysmograph for the measurement of cutaneous blood flow», *Physics in Medicine and Biology* **19**(3), págs. 317-328, DOI: [10.1088/0031-9155/19/3/003](https://doi.org/10.1088/0031-9155/19/3/003) (vid. pág. 30).
- Chan, K. H.; Peiris, J. S.; Lam, S. Y.; Poon, L. L.; Yuen, K. Y. y Seto, W. H. (2011), «The effects of temperature and relative humidity on the viability of the SARS coronavirus», *Advances in Virology* **2011**, DOI: [10.1155/2011/734690](https://doi.org/10.1155/2011/734690) (vid. pág. 45).
- Christensen, D. L.; Bilder, D. A.; Zahorodny, W.; Pettygrove, S.; Durkin, M. S.; Fitzgerald, R. T.; Rice, C.; Kurzius-Spencer, M.; Baio, J. y Yeargin-Allsopp, M. (2016), «Prevalence and characteristics of autism spectrum disorder among 4-year-old children in the autism and developmental disabilities monitoring network», *Journal of Developmental and Behavioral Pediatrics* **37**(1), págs. 1-8, DOI: [10.1097/DBP.0000000000000235](https://doi.org/10.1097/DBP.0000000000000235) (vid. pág. 1).
- Christiansz, J. A.; Gray, K. M.; Taffe, J. y Tonge, B. J. (2016), «Autism Spectrum Disorder in the DSM-5: Diagnostic Sensitivity and Specificity in Early Childhood», *Journal of Autism and Developmental Disorders* **46**(6), págs. 2054-2063, DOI: [10.1007/s10803-016-2734-4](https://doi.org/10.1007/s10803-016-2734-4) (vid. pág. 15).
- Clark, C.; Crumpler, C. y Notley, H. (2020), «Evidence for environmental noise effects on health for the United Kingdom policy context: A systematic review of the effects of environmental noise on mental health, wellbeing, quality of life, cancer, dementia, birth, reproductive outcomes, and cognition», *International Journal of Environmental Research and Public Health* **17**(2), DOI: [10.3390/ijerph17020393](https://doi.org/10.3390/ijerph17020393) (vid. pág. 56).
- Comission, E. (2018), *Autism Spectrum Disorders in the European Union (ASDEU)*, inf. téc., European Comission, Retrieved from <http://asdeu.eu/> (vid. pág. 4).
- Cornet, G. (2013), «Robot companions and ethics: a pragmatic approach of ethical design», *Journal International de Bioethique* **24**(4), págs. 49-58, DOI: [10.3917/jib.243.0049](https://doi.org/10.3917/jib.243.0049) (vid. pág. 22).
- Corporation, I. -. T. (2016), *MPU-9250 Product Specification Revision 1.1*, Retrieved from <https://invensense.tdk.com/wp-content/uploads/2015/02/PS-MPU-9250A-01-v1.1.pdf> (vid. pág. 34).

- Coulter, R. A. (2009), «Understanding the visual symptoms of individuals with autism spectrum disorder (ASD)», *Optometry and Vision Development* **40**(3), págs. 164-175 (vid. pág. 47).
- Cui, W.; Ostrander, L. y Lee, B. (1990), «In vivo reflectance of blood and tissue as a function of light wavelength», *IEEE Transactions on Biomedical Engineering* **37**(6), págs. 632-639, DOI: [10.1109/10.55667](https://doi.org/10.1109/10.55667) (vid. pág. 30).
- Danesh, A. A. y Kaf, W. A. (2012), «DPOAEs and contralateral acoustic stimulation and their link to sound hypersensitivity in children with autism», *International Journal of Audiology* **51**(4), págs. 345-352, DOI: [10.3109/14992027.2011.626202](https://doi.org/10.3109/14992027.2011.626202) (vid. pág. 59).
- Diagnostic and statistical manual of mental disorders (5th ed.)* (2013), American Psychiatric Association, DOI: <https://doi.org/10.1176/appi.books.9780890425596> (vid. págs. 2, 5, 15).
- Disease Control, C. for y Prevention (2021), *People with Disabilities*, Retrieved from <https://www.cdc.gov/ncbddd/disabilityandhealth/people.html> (vid. pág. 18).
- Drewry, A. M.; Fuller, B. M.; Bailey, T. C. y Hotchkiss, R. S. (2013), «Body temperature patterns as a predictor of hospital-acquired sepsis in afebrile adult intensive care unit patients : a case-control study», *Critical Care* **17**(5), R200, DOI: [10.1186/cc12894](https://doi.org/10.1186/cc12894) (vid. pág. 27).
- Dworzynski, K.; Ronald, A.; Bolton, P. y Happé, F. (2012), «How Different Are Girls and Boys Above and Below the Diagnostic Threshold for Autism Spectrum Disorders?», *Journal of the American Academy of Child and Adolescent Psychiatry* **51**(8), págs. 788-797, DOI: <https://doi.org/10.1016/j.jaac.2012.05.018> (vid. pág. 1).
- Eggenberger, P.; Macrae, B. A.; Kemp, S.; Bürgisser, M.; Rossi, R. M. y Annaheim, S. (2018), «Prediction of Core Body Temperature Based on Skin Temperature , Heat Flux , and Heart Rate Under Different Exercise and Clothing Conditions in the Heat in Young Adult Males», *Frontiers in Physiology* **9**, pág. 1780, DOI: [10.3389/fphys.2018.01780](https://doi.org/10.3389/fphys.2018.01780) (vid. pág. 27).
- Electroacoustics-Sound Level Meters-Part 1: Specifications* (2013), inf. téc., Standard IEC 61672-1:2013, International Electrotechnical Commission (vid. pág. 60).
- Elgendi, M.; Fletcher, R.; Liang, Y.; Howard, N.; Lovell, N. H.; Abbott, D.; Lim, K. y Ward, R. (2019), «The use of photoplethysmography for assessing hypertension», *npj Digital Medicine* **2**(1), págs. 1-11, DOI: [10.1038/s41746-019-0136-7](https://doi.org/10.1038/s41746-019-0136-7) (vid. pág. 30).
- Elsabbagh, M.; Divan, G.; Koh, Y. J.; Kim, Y. S.; Kauchali, S.; Marcín, C.; Montiel-Nava, C.; Patel, V.; Paula, C. S.; Wang, C.; Yasamy, M. T. y Fombonne, E. (2012), «Global Prevalence of Autism and Other Pervasive Developmental Disorders», *Autism Research* **5**(3), págs. 160-179, DOI: [10.1002/aur.239](https://doi.org/10.1002/aur.239) (vid. pág. 1).

- Empatica (2021), *Embrace 2 - Smarter Epilepsy Management*, Retrieved from <https://www.empatica.com/en-gb/embrace2/> (vid. pág. 18).
- Essalat, M.; Mashhadi, M. B. y Marvasti, F. (2017), «Supervised heart rate tracking using wrist-type photoplethysmographic (PPG) signals during physical exercise without simultaneous acceleration signals», en: IEEE, págs. 1166-1170, ISBN: 9781509045457, DOI: [10.1109/GlobalSIP.2016.7906025](https://doi.org/10.1109/GlobalSIP.2016.7906025) (vid. pág. 127).
- Esteva, A.; Kuprel, B.; Novoa, R. A.; Ko, J.; Swetter, S. M.; Blau, H. M. y Thrun, S. (2017), «Dermatologist-level classification of skin cancer with deep neural networks», *Nature* **542**(7639), págs. 115-118, DOI: [10.1038/nature21056](https://doi.org/10.1038/nature21056) (vid. pág. 22).
- Farnebäck, G. (2003), «Two-Frame Motion Estimation Based on Polynomial Expansion», en: *Image Analysis*, ed. por J. Bigun y T. Gustavsson, Berlin, Heidelberg: Springer Berlin Heidelberg, págs. 363-370, ISBN: 978-3-540-45103-7 (vid. pág. 57).
- Fitbit (2021), *Fitbit Sense*, Retrieved from <https://www.fitbit.com/global/us/products/smartwatches/sense> (vid. pág. 17).
- Fox, K.; Borer, J. S.; Camm, A. J.; Danchin, N.; Ferrari, R.; Lopez Sendon, J. L.; Steg, P. G.; Tardif, J.-C.; Tavazzi, L. y Tendera, M. (2007), «Resting Heart Rate in Cardiovascular Disease», *Journal of the American College of Cardiology* **50**(9), págs. 823-830, DOI: <https://doi.org/10.1016/j.jacc.2007.04.079> (vid. pág. 29).
- Garland, M.; Le Grand, S.; Nickolls, J.; Anderson, J.; Hardwick, J.; Morton, S.; Phillips, E.; Zhang, Y. y Volkov, V. (2008), «Parallel Computing Experiences with CUDA», *IEEE Micro* **28**(4), págs. 13-27, DOI: [10.1109/MM.2008.57](https://doi.org/10.1109/MM.2008.57) (vid. pág. 54).
- Gordon, C. J. y Yang, Y. (1997), «Contribution of spontaneous motor activity to the 24 hour control of body temperature in male and female rats», *Journal of Thermal Biology* **22**(1), págs. 59-68, DOI: [https://doi.org/10.1016/S0306-4565\(96\)00035-6](https://doi.org/10.1016/S0306-4565(96)00035-6) (vid. pág. 27).
- Gould, J. (2017), «Towards understanding the under-recognition of girls and women on the autism spectrum», *Autism* **21**(6), págs. 703-705, DOI: [10.1177/1362361317706174](https://doi.org/10.1177/1362361317706174) (vid. pág. 1).
- Gould, J. y Ashton-Smith, J. (2011), «Missed diagnosis or misdiagnosis? Girls and women on the autism spectrum», *Good Autism Practice (GAP)* **12** (vid. pág. 1).
- Grosan, C. y Abraham, A. (2011), *Intelligent Systems, A Modern Approach*, vol. 17, Springer-Verlag Berlin Heidelberg, DOI: [10.1007/978-3-642-21004-4](https://doi.org/10.1007/978-3-642-21004-4) (vid. pág. 53).
- Gulshan, V.; Peng, L.; Coram, M.; Stumpe, M. C.; Wu, D.; Narayanaswamy, A.; Venugopalan, S.; Widner, K.; Madams, T.; Cuadros, J.; Kim, R.; Raman, R.; Nelson, P. C.; Mega, J. L. y Webster, D. R. (2016), «Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal

- fundus photographs», *JAMA - Journal of the American Medical Association* **316**(22), págs. 2402-2410, DOI: [10.1001/jama.2016.17216](https://doi.org/10.1001/jama.2016.17216) (vid. pág. 22).
- Hajat, S. y Haines, A. (2002), «Associations of cold temperatures with GP consultations for respiratory and cardiovascular disease amongst the elderly in London», *International Journal of Epidemiology* **31**(4), págs. 825-830, DOI: [10.1093/ije/31.4.825](https://doi.org/10.1093/ije/31.4.825), eprint: <https://academic.oup.com/ije/article-pdf/31/4/825/18478963/310825.pdf> (vid. pág. 45).
- Hamet, P. y Tremblay, J. (2017), «Artificial intelligence in medicine», *Metabolism: Clinical and Experimental* **69**, S36-S40, DOI: [10.1016/j.metabol.2017.01.011](https://doi.org/10.1016/j.metabol.2017.01.011) (vid. pág. 21).
- Hamilton, M. T.; Hamilton, D. G. y Zderic, T. W. (2014), «Sedentary behavior as a mediator of type 2 diabetes», *Diabetes and Physical Activity* **60**, págs. 11-26, DOI: [10.1159/000357332](https://doi.org/10.1159/000357332) (vid. pág. 32).
- Hammel, H. T.; Jackson, D. C.; Stolwijk, J. A. J.; Hardy, J. D. y Stromme, S. B. (1963), «Temperature regulation by hypothalamic proportional control with an adjustable set point», *Journal of Applied Physiology* **18**(6), págs. 1146-1154, DOI: [10.1152/jappl.1963.18.6.1146](https://doi.org/10.1152/jappl.1963.18.6.1146), eprint: <https://doi.org/10.1152/jappl.1963.18.6.1146> (vid. pág. 27).
- Happé, F. G.; Mansour, H.; Barrett, P.; Brown, T.; Abbott, P. y Charlton, R. A. (2016), «Demographic and Cognitive Profile of Individuals Seeking a Diagnosis of Autism Spectrum Disorder in Adulthood», *Journal of Autism and Developmental Disorders* **46**(11), págs. 3469-3480, DOI: [10.1007/s10803-016-2886-2](https://doi.org/10.1007/s10803-016-2886-2) (vid. pág. 3).
- Harris, J.; Allen, D.; Cornick, M.; Jefferson, A. y Mills, R. (1997), «Physical Interventions: a Policy Framework», *Tizard Learning Disability Review* **2**(3), págs. 41-42, DOI: [10.1108/13595474199700028](https://doi.org/10.1108/13595474199700028) (vid. pág. 5).
- Heckbert, P. (1995), «Fourier Transforms and the Fast Fourier Transform (FFT) Algorithm», *Notes Computer Graphics* **3**(2), págs. 15-463 (vid. pág. 80).
- Henry, J. D.; Von Hippel, W.; Molenberghs, P.; Lee, T. y Sachdev, P. S. (2016), «Clinical assessment of social cognitive function in neurological disorders», *Nature Reviews Neurology* **12**(1), págs. 28-39, DOI: [10.1038/nrneuro.2015.229](https://doi.org/10.1038/nrneuro.2015.229) (vid. pág. 53).
- Hill, A. P.; Zuckerman, K. E.; Hagen, A. D.; Kriz, D. J.; Duvall, S. W.; Van Santen, J.; Nigg, J.; Fair, D. y Fombonne, E. (2014), «Aggressive behavior problems in children with autism spectrum disorders: Prevalence and correlates in a large clinical sample», *Research in Autism Spectrum Disorders* **8**(9), págs. 1121-1133, DOI: [10.1016/j.rasd.2014.05.006](https://doi.org/10.1016/j.rasd.2014.05.006) (vid. pág. 5).
- Hillier, A.; Fish, T.; Cloppert, P. y Beversdorf, D. Q. (2007), «Outcomes of a Social and Vocational Skills Support Group for Adolescents and Young Adults on the Autism Spectrum», *Focus on Autism and Other Developmental Disabilities* **22**(2), págs. 107-115,

- DOI: [10.1177/10883576070220020201](https://doi.org/10.1177/10883576070220020201), eprint: <https://doi.org/10.1177/10883576070220020201> (vid. pág. 16).
- Hillman, C. H.; Erickson, K. I. y Kramer, A. F. (2008), «Be smart, exercise your heart: exercise effects on brain and cognition», *Nature Reviews Neuroscienc* **9**(1), págs. 58-65, DOI: [10.1038/nrn2298](https://doi.org/10.1038/nrn2298) (vid. pág. 32).
- Hirvikoski, T.; Mittendorfer-Rutz, E.; Boman, M.; Larsson, H.; Lichtenstein, P. y Bölte, S. (2016), «Premature mortality in autism spectrum disorder», *British Journal of Psychiatry* **208**(3), págs. 232-238, DOI: [10.1192/bjp.bp.114.160192](https://doi.org/10.1192/bjp.bp.114.160192) (vid. pág. 4).
- Howlin, P.; Moss, P.; Savage, S. y Rutter, M. (2013), «Social Outcomes in Mid- to Later Adulthood Among Individuals Diagnosed With Autism and Average Nonverbal IQ as Children», *Journal of the American Academy of Child & Adolescent Psychiatry* **52**(6), 572-581.e1, DOI: <https://doi.org/10.1016/j.jaac.2013.02.017> (vid. pág. 3).
- Instruments, T. (2016), *HDC1010 Low Power, High Accuracy Digital Humidity Sensor with Temperature Sensor*, Retrieved from <https://www.ti.com/lit/ds/symlink/hdc1010.pdf> (vid. pág. 45).
- Instruments, T. (2017), *OPT3001 Ambient Light Sensor (ALS)*, Retrieved from <https://www.ti.com/lit/ds/symlink/opt3001.pdf> (vid. pág. 48).
- Integrated, M. (2016), *MAX30205 Human Body Temperature Sensor*, Retrieved from <https://datasheets.maximintegrated.com/en/ds/MAX30205.pdf> (vid. pág. 27).
- Integrated, M. (2019), *MAX86160 Integrated Heart-Rate Sensor for In-Ear Applications*, Retrieved from <https://datasheets.maximintegrated.com/en/ds/MAX86160.pdf> (vid. pág. 31).
- Jänig, W. y Häbler, H.-J. (2000), «Chapter 25 - Specificity in the organization of the autonomic nervous system: a basis for precise neural regulation of homeostatic and protective body functions», en: *The Biological Basis for Mind Body Interactions*, ed. por E. Mayer y C. Saper, vol. 122, Progress in Brain Research, Elsevier, págs. 351-367, DOI: [https://doi.org/10.1016/S0079-6123\(08\)62150-0](https://doi.org/10.1016/S0079-6123(08)62150-0) (vid. pág. 29).
- Jocher, G.; Stoken, A.; Borovec, J.; NanoCode012; ChristopherSTAN; Changyu, L.; Laughing; tkianai; yxNONG; Hogan, A.; lorenzomamma; AlexWang1900; Chaurasia, A.; Diaconu, L.; Marc; wanghaoyango106; ml5ah; Doug; Durgesh; Ingham, F.; Frederik; Guilhen; Colmagro, A.; Ye, H.; Jacobsolawetz; Poznanski, J.; Fang, J.; Kim, J.; Doan, K. y Yu, L. (2021), *ultralytics/yolov5: v4.0 - nn.SiLU() activations, Weights & Biases logging, PyTorch Hub integration*, ver. v4.0, DOI: [10.5281/zenodo.4418161](https://doi.org/10.5281/zenodo.4418161) (vid. pág. 56).

- Jones, D. P. (1987), «Medical electro-optics: measurements in the human microcirculation», *Physics in Technology* **18**(2), págs. 79-85, DOI: [10.1088/0305-4624/18/2/305](https://doi.org/10.1088/0305-4624/18/2/305) (vid. pág. 30).
- Kellogg, D. L. (2006), «In vivo mechanisms of cutaneous vasodilation and vasoconstriction in humans during thermoregulatory challenges», *Journal of Applied Physiology* **100**(5), págs. 1709-1718, DOI: [10.1152/jappphysiol.01071.2005](https://doi.org/10.1152/jappphysiol.01071.2005) (vid. pág. 27).
- Kelly, G. (2006), «Body temperature variability (Part 1): a review of the history of body temperature and its variability due to site selection, biological rhythms, fitness, and aging.», *Alternative Medicine Review* **11**(04), págs. 211-278 (vid. pág. 28).
- Kelly, G. S. (2007), «Body temperature variability (part 2): Masking influences of body temperature variability and a review of body temperature variability in disease», *Alternative Medicine Review* **12**(1), págs. 49-62 (vid. pág. 28).
- Khayyam, H.; Javadi, B.; Jalili, M. y Jazar, R. N. (2020), «Artificial Intelligence and Internet of Things for Autonomous Vehicles», en: *Nonlinear Approaches in Engineering Applications: Automotive Applications of Engineering Problems*, ed. por R. N. Jazar y L. Dai, Springer International Publishing, págs. 39-68, ISBN: 978-3-030-18963-1, DOI: [10.1007/978-3-030-18963-1_2](https://doi.org/10.1007/978-3-030-18963-1_2) (vid. pág. 20).
- Khurana, U.; Turaga, D.; Samulowitz, H. y Parthasarathy, S. (2016), «Cognito: Automated Feature Engineering for Supervised Learning», *IEEE International Conference on Data Mining Workshops, ICDMW* **0**, págs. 1304-1307, DOI: [10.1109/ICDMW.2016.0190](https://doi.org/10.1109/ICDMW.2016.0190) (vid. pág. 75).
- Kira, K. y Rendell, L. A. (1992), «A Practical Approach to Feature Selection», en: *Machine Learning Proceedings 1992*, ed. por D. Sleeman y P. Edwards, San Francisco (CA): Morgan Kaufmann, págs. 249-256, ISBN: 978-1-55860-247-2, DOI: <https://doi.org/10.1016/B978-1-55860-247-2.50037-1> (vid. pág. 137).
- Klintwall, L.; Holm, A.; Eriksson, M.; Carlsson, L. H.; Olsson, M. B.; Hedvall, Å.; Gillberg, C. y Fernell, E. (2011), «Sensory abnormalities in autism. A brief report», *Research in Developmental Disabilities* **32**(2), págs. 795-800, DOI: [10.1016/j.ridd.2010.10.021](https://doi.org/10.1016/j.ridd.2010.10.021) (vid. pág. 7).
- Kozima, H.; Nakagawa, C. y Yasuda, Y. (2007), «Children–robot interaction: a pilot study in autism therapy», *Progress in Brain Research* **164**, ed. por C. von Hofsten y K. Rosander, págs. 385-400, DOI: [https://doi.org/10.1016/S0079-6123\(07\)64021-7](https://doi.org/10.1016/S0079-6123(07)64021-7) (vid. pág. 22).
- Kreibig, S. D. (2010), «Autonomic nervous system activity in emotion: A review», *Biological Psychology* **84**(3), The biopsychology of emotion: Current theoretical and

- empirical perspectives, págs. 394-421, DOI: <https://doi.org/10.1016/j.biopsycho.2010.03.010> (vid. pág. 30).
- Lang, R.; Regester, A.; Lauderdale, S.; Ashbaugh, K. y Haring, A. (2010), «Treatment of anxiety in autism spectrum disorders using cognitive behaviour therapy: A systematic review», *Developmental Neurorehabilitation* **13**(1), págs. 53-63, DOI: [10.3109/17518420903236288](https://doi.org/10.3109/17518420903236288), eprint: <https://doi.org/10.3109/17518420903236288> (vid. pág. 16).
- Lee, J.; Kim, M.; Park, H. K. y Kim, I. Y. (2020), «Motion artifact reduction in wearable photoplethysmography based on multi-channel sensors with multiple wavelengths», *Sensors (Switzerland)* **20**(5), DOI: [10.3390/s20051493](https://doi.org/10.3390/s20051493) (vid. págs. 126, 130).
- Leekam, S. R.; Nieto, C.; Libby, S. J.; Wing, L. y Gould, J. (2007), «Describing the sensory abnormalities of children and adults with autism», *Journal of Autism and Developmental Disorders* **37**(5), págs. 894-910, DOI: [10.1007/s10803-006-0218-7](https://doi.org/10.1007/s10803-006-0218-7) (vid. pág. 5).
- Lenglet, A. D.; Hernando, V.; Rodrigo, P.; Larrauri, A.; Donado, J. D. y De Mateo, S. (2007), «Impact of flu on hospital admissions during 4 flu seasons in Spain, 2000-2004», *BMC Public Health* **7**, págs. 1-7, DOI: [10.1186/1471-2458-7-197](https://doi.org/10.1186/1471-2458-7-197) (vid. pág. 45).
- Li, R.; Zhang, W.; Suk, H. I.; Wang, L.; Li, J.; Shen, D. y Ji, S. (2014), «Deep learning based imaging data completion for improved brain disease diagnosis», *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* **8675 LNCS(PART 3)**, págs. 305-312, DOI: [10.1007/978-3-319-10443-0_39](https://doi.org/10.1007/978-3-319-10443-0_39) (vid. pág. 22).
- Lin, T.-Y.; Maire, M.; Belongie, S.; Hays, J.; Perona, P.; Ramanan, D.; Dollár, P. y Zitnick, C. L. (2014), «Microsoft COCO: Common Objects in Context», en: *Computer Vision – ECCV 2014*, Springer International Publishing, págs. 740-755, ISBN: 978-3-319-10602-1 (vid. pág. 56).
- Lin, W. C.; Chen, J. S.; Chiang, M. F. y Hribar, M. R. (2020), «Applications of artificial intelligence to electronic health record data in ophthalmology», *Translational Vision Science and Technology* **9**(2), DOI: [10.1167/tvst.9.2.13](https://doi.org/10.1167/tvst.9.2.13) (vid. pág. 22).
- Lord, C.; Elsabbagh, M.; Baird, G. y Veenstra-Vanderweele, J. (2018), «Autism spectrum disorder», *The Lancet* **392**(10146), págs. 508-520, DOI: [https://doi.org/10.1016/S0140-6736\(18\)31129-2](https://doi.org/10.1016/S0140-6736(18)31129-2) (vid. pág. 1).
- Lord, C.; Rutter, M.; Goode, S.; Heemsbergen, J.; Jordan, H.; Mawhood, L. y Schopler, E. (1989), «Autism diagnostic observation schedule: A standardized observation of communicative and social behavior», *Journal of Autism and Developmental Disorders* **19**(2), págs. 185-212, DOI: [10.1007/BF02211841](https://doi.org/10.1007/BF02211841) (vid. pág. 2).
- Mäkinen, T. M.; Juvonen, R.; Jokelainen, J.; Harju, T. H.; Peitso, A.; Bloigu, A.; Silvennoinen-Kassinen, S.; Leinonen, M. y Hassi, J. (2009), «Cold temperature and low

- humidity are associated with increased occurrence of respiratory tract infections», *Respiratory Medicine* **103**(3), págs. 456-462, DOI: [10.1016/j.rmed.2008.09.011](https://doi.org/10.1016/j.rmed.2008.09.011) (vid. pág. 45).
- Massin, M. M.; Maeyns, K.; Withofs, N.; Ravet, F. y Gérard, P. (2000), «Circadian rhythm of heart rate and heart rate variability», *Archives of Disease in Childhood* **83**(2), págs. 179-182, DOI: [10.1136/adc.83.2.179](https://doi.org/10.1136/adc.83.2.179) (vid. pág. 30).
- Mazurek, M. O.; Curran, A.; Burnette, C. y Sohl, K. (2019), «ECHO Autism STAT: Accelerating Early Access to Autism Diagnosis», *Journal of Autism and Developmental Disorders* **49**(1), págs. 127-137, DOI: [10.1007/s10803-018-3696-5](https://doi.org/10.1007/s10803-018-3696-5) (vid. pág. 2).
- McCarthy, J.; Minsky, M.; Rochester, N. y Shannon, C. (1955), «A proposal for the Dartmouth summer research project on artificial intelligence», págs. 1-13 (vid. pág. 20).
- McGrath, J. A.; Eady, R. A. J. y Pope, F. M. (2004), «Anatomy and Organization of Human Skin», en: *Rook's Textbook of Dermatology*, John Wiley & Sons, Ltd, cap. 3, págs. 45-128, ISBN: 9780470750520, DOI: <https://doi.org/10.1002/9780470750520.ch3> (vid. pág. 27).
- Medtronic (2021), *Zephyr Performance Systems*, Retrieved from <https://www.zephyranywhere.com/> (vid. págs. 18, 131).
- Merriam, J. B. (1992), «Atmospheric pressure and gravity», *Geophysical Journal International* **109**(3), págs. 488-500, DOI: [10.1111/j.1365-246X.1992.tb00112.x](https://doi.org/10.1111/j.1365-246X.1992.tb00112.x), eprint: <https://academic.oup.com/gji/article-pdf/109/3/488/1975692/109-3-488.pdf> (vid. pág. 46).
- Michael, P. R.; Johnston, D. E. y Moreno, W. (2020), «A conversion guide: solar irradiance and lux illuminance», *Journal of Measurements in Engineering* **8**(4), págs. 153-166, DOI: [10.21595/jme.2020.21667](https://doi.org/10.21595/jme.2020.21667) (vid. pág. 48).
- Mintz, Y. y Brodie, R. (2019), «Introduction to artificial intelligence in medicine», *Minimally Invasive Therapy and Allied Technologies* **28**(2), págs. 73-81, DOI: [10.1080/13645706.2019.1575882](https://doi.org/10.1080/13645706.2019.1575882) (vid. pág. 21).
- Misawa, M.; Kudo, S.-e.; Mori, Y.; Cho, T.; Kataoka, S.; Yamauchi, A.; Ogawa, Y.; Maeda, Y.; Takeda, K.; Ichimasa, K.; Nakamura, H.; Yagawa, Y.; Toyoshima, N.; Ogata, N.; Kudo, T.; Hisayuki, T.; Hayashi, T.; Wakamura, K.; Baba, T.; Ishida, F.; Itoh, H.; Roth, H.; Oda, M. y Mori, K. (2018), «Artificial Intelligence-Assisted Polyp Detection for Colonoscopy: Initial Experience», *Gastroenterology* **154**(8), págs. 2027-2029, DOI: [10.1053/j.gastro.2018.04.003](https://doi.org/10.1053/j.gastro.2018.04.003) (vid. pág. 22).
- MongoDB (2021), *The Most Popular Database for Modern Apps | MongoDB*, Retrieved from <https://www.mongodb.com> (vid. pág. 70).

- Moore, S. C.; Lee, I. M.; Weiderpass, E.; Campbell, P. T.; Sampson, J. N.; Kitahara, C. M.; Keadle, S. K.; Arem, H.; De Gonzalez, A. B.; Hartge, P.; Adami, H. O.; Blair, C. K.; Borch, K. B.; Boyd, E.; Check, D. P.; Fournier, A.; Freedman, N. D.; Gunter, M.; Johannson, M.; Khaw, K. T.; Linet, M. S.; Orsini, N.; Park, Y.; Riboli, E.; Robien, K.; Schairer, C.; Sesso, H.; Spriggs, M.; Van Dusen, R.; Wolk, A.; Matthews, C. E. y Patel, A. V. (2016), «Association of leisure-time physical activity with risk of 26 types of cancer in 1.44 million adults», *JAMA Internal Medicine* **176**(6), págs. 816-825, DOI: [10.1001/jamainternmed.2016.1548](https://doi.org/10.1001/jamainternmed.2016.1548) (vid. pág. 32).
- Mulder, L. (1992), «Measurement and analysis methods of heart rate and respiration for use in applied environments», *Biological Psychology* **34**(2), Special Issue Cardiorespiratory Measures and thier Role in Studies of Performance, págs. 205-236, DOI: [https://doi.org/10.1016/0301-0511\(92\)90016-N](https://doi.org/10.1016/0301-0511(92)90016-N) (vid. pág. 29).
- Murray, A. y Marjanovic, D. (1997), «Optical assessment of recovery of tissue blood supply after removal of externally applied pressure», *Medical and Biological Engineering and Computing* **35**(4), págs. 425-427, DOI: [10.1007/BF02534102](https://doi.org/10.1007/BF02534102) (vid. pág. 30).
- Myers, J.; McAuley, P.; Lavie, C. J.; Despres, J. P.; Arena, R. y Kokkinos, P. (2015), «Physical Activity and Cardiorespiratory Fitness as Major Markers of Cardiovascular Risk: Their Independent and Interwoven Importance to Health Status», *Progress in Cardiovascular Diseases* **57**(4), págs. 306-314, DOI: [10.1016/j.pcad.2014.09.011](https://doi.org/10.1016/j.pcad.2014.09.011) (vid. pág. 32).
- NeuroSigma (2021), *Monarch eTNS System for Treating Pediatric ADHD*, Retrieved from <https://www.monarch-etns.com/> (vid. pág. 19).
- Neurotechnology, P. (2021), *PD Monitor Solution*, Retrieved from <https://www.pdneurotechnology.com/pd-monitor-solution/product/> (vid. pág. 19).
- Nvidia (2021), *Jetson Nano*, Retrieved from <https://developer.nvidia.com/embedded/jetson-nano> (vid. pág. 54).
- Omar, K. S.; Rabbi, F.; Anjum, A.; Oannahary, T.; Karim Rizvi, R.; Shahrin, D.; Anannya, T. T.; Nasreen Tumpa, S.; Karim, M. y Nazrul Islam, M. (2019), «An Intelligent Assistive Tool for Alzheimer's Patient», *1st International Conference on Advances in Science* **2019**(Icasert), DOI: [10.1109/ICASERT.2019.8934542](https://doi.org/10.1109/ICASERT.2019.8934542) (vid. pág. 19).
- OpenCV (2021), *OpenCV: Optical FLOW*, Retrieved from https://docs.opencv.org/3.4/d4/dee/tutorial_optical_flow.html (vid. pág. 57).
- Organization, W. H. (2021), *Autism spectrum disorders*, Retrieved from <https://www.who.int/news-room/fact-sheets/detail/autism-spectrum-disorders> (vid. pág. 1).

- Ortiz Huerta, J. (2014), «Terapia de integración sensorial en niños con trastorno de espectro autista», *Revista electrónica de terapia ocupacional Galicia, TOG* **11**(19), pág. 5 (vid. pág. 5).
- Ortiz-Tudela, E.; Martínez-Nicolas, A.; Albares, J.; Segarra, F.; Campos, M.; Estivill, E.; Rol, M. A. y Madrid, J. A. (2014), «Ambulatory Circadian Monitoring (ACM) based on Thermometry, motor Activity and body Position (TAP): A comparison with polysomnography», *Physiology and Behavior* **126**, págs. 30-38, DOI: [10.1016/j.physbeh.2013.12.009](https://doi.org/10.1016/j.physbeh.2013.12.009) (vid. pág. 27).
- Pascual, M. G. (2021), *El reconocimiento facial chino llega a las puertas de la Unión Europea*, Retrieved from <https://elpais.com/tecnologia/2021-06-18/el-reconocimiento-facial-chino-llega-a-las-puertas-de-la-union-europea.html> (vid. pág. 20).
- Pezoa, F.; Reutter, J. L.; Suarez, F.; Ugarte, M. y Vrgoč, D. (2016), «Foundations of JSON schema», *25th International World Wide Web Conference, WWW 2016*, págs. 263-273, DOI: [10.1145/2872427.2883029](https://doi.org/10.1145/2872427.2883029) (vid. pág. 67).
- Pfeiffer, B. A.; Koenig, K.; Kinnealey, M.; Sheppard, M. y Henderson, L. (2013), «Effectiveness of Sensory Integration Interventions in children with autism spectrum disorders: A pilot study», *National Institutes of Health* **65**(1), págs. 76-85 (vid. pág. 5).
- Prevedello, L. M.; Erdal, B. S.; Ryu, J. L.; Little, K. J.; Demirer, M.; Qian, S. y White, R. D. (2017), «Automated Critical Test Findings Identification and Online Notification System Using Artificial Intelligence in Imaging», *Radiology* **285**(3), págs. 923-931, DOI: [10.1148/radiol.2017162664](https://doi.org/10.1148/radiol.2017162664) (vid. pág. 22).
- Refaeilzadeh, P.; Tang, L. y Liu, H. (2016), «Cross-Validation», en: *Encyclopedia of Database Systems*, ed. por L. Liu y M. T. Özsu, New York, NY: Springer New York, págs. 1-7, ISBN: 978-1-4899-7993-3, DOI: [10.1007/978-1-4899-7993-3_565-2](https://doi.org/10.1007/978-1-4899-7993-3_565-2) (vid. pág. 99).
- Reichow, B.; Barton, E. E.; Boyd, B. A. y Hume, K. (2012), «Early intensive behavioral intervention (EIBI) for young children with autism spectrum disorders (ASD)», *Cochrane Database of Systematic Reviews* (5), DOI: [10.1002/14651858.CD009260.pub2](https://doi.org/10.1002/14651858.CD009260.pub2) (vid. pág. 16).
- Rockette-Wagner, B.; Storti, K. L.; Edelstein, S.; Delahanty, L. M.; Galvin, B.; Jackson, A. y Kriska, A. M. (2017), «Measuring Physical Activity and Sedentary Behavior in Youth with Type 2 Diabetes», *Childhood Obesity* **13**(1), págs. 72-77, DOI: [10.1089/chi.2015.0151](https://doi.org/10.1089/chi.2015.0151) (vid. pág. 33).
- Romanovsky, A. A. (2014), «Skin temperature: its role in thermoregulation», *Acta Physiologica* **210**(3), págs. 498-507, DOI: <https://doi.org/10.1111/apha.12231> (vid. pág. 27).

- Rosenkrantz, A. B.; Hughes, D. R. y Duszak, R. (2016), «The U.S. radiologist workforce: An analysis of temporal and geographic variation by using large national datasets», *Radiology* **279**(1), págs. 175-184, DOI: [10.1148/radiol.2015150921](https://doi.org/10.1148/radiol.2015150921) (vid. pág. 22).
- Rutter, M. (2005), «Autism Research: Lessons from the Past and Prospects for the Future», *Journal of Autism and Developmental Disorders* **35**, págs. 241-257, DOI: [10.1007/s10803-004-2003-9](https://doi.org/10.1007/s10803-004-2003-9) (vid. pág. 1).
- Samsung (2021), *Samsung Galaxy Watch 3*, Retrieved from <https://www.samsung.com/global/galaxy/galaxy-watch3/specs/> (vid. pág. 17).
- Saper, C. B. (2013), «The central circadian timing system», *Current Opinion in Neurobiology* **23**(5), págs. 747-751, DOI: [10.1016/j.conb.2013.04.004](https://doi.org/10.1016/j.conb.2013.04.004) (vid. pág. 32).
- Six, J.; Cornelis, O. y Leman, M. (2014), «TarsosDSP, a real-time audio processing framework in Java», *Proceedings of the AES International Conference*, págs. 240-246 (vid. pág. 60).
- Slomka, P. J.; Dey, D.; Sitek, A.; Motwani, M.; Berman, D. S. y Germano, G. (2017), «Cardiac imaging: working towards fully-automated machine analysis & interpretation», *Expert Review of Medical Devices* **14**(3), págs. 197-212, DOI: [10.1080/17434440.2017.1300057](https://doi.org/10.1080/17434440.2017.1300057) (vid. pág. 22).
- Standard ASTM E1112-00(2018)* (2018), Standard Specification for Electronic Thermometer for Intermittent Determination of Patient Temperature, ASTM International, DOI: [10.1520/E1112-00R18](https://doi.org/10.1520/E1112-00R18) (vid. pág. 28).
- Stepanova, E.; Dowling, S.; Phelps, M. y Findling, R. L. (2017), «Pharmacotherapy of emotional and behavioral symptoms associated with autism spectrum disorder in children and adolescents», *Dialogues in clinical neuroscience* **19**(4), págs. 395-402, DOI: [10.31887/DCNS.2017.19.4/rfindling](https://doi.org/10.31887/DCNS.2017.19.4/rfindling) (vid. pág. 17).
- Stiegler, L. N. y Davis, R. (2010), «Understanding sound sensitivity in individuals with autism spectrum disorders», *Focus on Autism and Other Developmental Disabilities* **25**(2), págs. 67-75, DOI: [10.1177/1088357610364530](https://doi.org/10.1177/1088357610364530) (vid. pág. 59).
- Swinehart, D. F. (1962), «The Beer-Lambert law», *Journal of Chemical Education* **39**(7), págs. 333-335, DOI: [10.1021/ed039p333](https://doi.org/10.1021/ed039p333) (vid. pág. 128).
- Szold, A.; Bergamaschi, R.; Broeders, I.; Dankelman, J.; Forgione, A.; Langø, T.; Melzer, A.; Mintz, Y.; Morales-Conde, S.; Rhodes, M.; Satava, R.; Tang, C. N. y Vilallonga, R. (2015), «European association of endoscopic surgeons (EAES) consensus statement on the use of robotics in general surgery», *Surgical Endoscopy* **29**(2), págs. 253-288, DOI: [10.1007/s00464-014-3916-9](https://doi.org/10.1007/s00464-014-3916-9) (vid. pág. 22).

- Tang, S. Y.; Hoang, N. S.; Chui, C. K.; Lim, J. H. y Chua, M. C. H. (2019), «Shi Yuan Tang, Ngoc Son Hoang, Chee Kong Chui, Jeong Hoon Lim, Matthew C. H. Chua», *117575*, págs. 626-631 (vid. pág. 22).
- Teare, P.; Fishman, M.; Benzaquen, O.; Toledano, E. y Elnekave, E. (2017), «Malignancy Detection on Mammography Using Dual Deep Convolutional Neural Networks and Genetically Discovered False Color Input Enhancement», *Journal of Digital Imaging* 30(4), págs. 499-505, DOI: [10.1007/s10278-017-9993-2](https://doi.org/10.1007/s10278-017-9993-2) (vid. pág. 22).
- Theofilatos, K.; Pavlopoulou, N.; Pappasavvas, C.; Likothanassis, S.; Dimitrakopoulos, C.; Georgopoulos, E.; Moschopoulos, C. y Mavroudi, S. (2015), «Predicting protein complexes from weighted protein-protein interaction graphs with a novel unsupervised methodology: Evolutionary enhanced Markov clustering», *Artificial Intelligence in Medicine* 63(3), págs. 181-189, DOI: <https://doi.org/10.1016/j.artmed.2014.12.012> (vid. pág. 21).
- Tiura, M.; Kim, J.; Detmers, D. y Baldi, H. (2017), «Predictors of longitudinal ABA treatment outcomes for children with autism: A growth curve analysis», *Research in Developmental Disabilities* 70, págs. 185-197, DOI: <https://doi.org/10.1016/j.ridd.2017.09.008> (vid. pág. 16).
- Tomchek, S. D. y Dunn, W. (2007), «Sensory processing in children with and without autism: a comparative study using the short sensory profile», *American Journal of Occupational Therapy* 61(2), págs. 190-200, DOI: [10.5014/ajot.61.2.190](https://doi.org/10.5014/ajot.61.2.190) (vid. pág. 7).
- Uijtdehaage, S. H. y Thayer, J. F. (2000), «Accentuated antagonism in the control of human heart rate», *Clinical Autonomic Research* 10(3), págs. 107-110, DOI: [10.1007/BF02278013](https://doi.org/10.1007/BF02278013) (vid. pág. 30).
- UMH, C. U. (2021), *Clínica Universitaria Universidad Miguel Hernández*, Retrieved from <https://clinicauniversitaria.umh.es/> (vid. pág. 102).
- Van Hilten, J.; Middelkoop, H.; Kuiper, S.; Kramer, C. y Roos, R. (1993), «Where to record motor activity: an evaluation of commonly used sites of placement for activity monitors», *Electroencephalography and Clinical Neurophysiology* 89(5), págs. 359-362, DOI: [10.1016/0168-5597\(93\)90076-2](https://doi.org/10.1016/0168-5597(93)90076-2) (vid. pág. 33).
- Vancampfort, D.; Firth, J.; Schuch, F. B.; Rosenbaum, S.; Mugisha, J.; Hallgren, M.; Probst, M.; Ward, P. B.; Gaughran, F.; De Hert, M.; Carvalho, A. F. y Stubbs, B. (2017), «Sedentary behavior and physical activity levels in people with schizophrenia, bipolar disorder and major depressive disorder: a global systematic review and meta-analysis», *World Psychiatry* 16(3), págs. 308-315, DOI: [10.1002/wps.20458](https://doi.org/10.1002/wps.20458) (vid. pág. 32).

- Wang, C.-Y.; Liao, H.-Y. M.; Wu, Y.-H.; Chen, P.-Y.; Hsieh, J.-W. y Yeh, I.-H. (2020), «CSPNet: A New Backbone That Can Enhance Learning Capability of CNN», en: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops* (vid. pág. 56).
- Wang, M.; Li, Z.; Zhang, Q. y Wang, G. (2019), «Removal of motion artifacts in photoplethysmograph sensors during intensive exercise for accurate heart rate calculation based on frequency estimation and notch filtering», *Sensors (Switzerland)* **19**(15), DOI: [10.3390/s19153312](https://doi.org/10.3390/s19153312) (vid. págs. 56, 126).
- Wang, S.-C. (2003), «Artificial neural network», en: *Interdisciplinary computing in java programming*, vol. 743, Springer, págs. 81-100, ISBN: 978-1-4615-0377-4 (vid. pág. 76).
- Weitlauf, A. S.; McPheeters, M. L.; Peters, B.; Sathe, N.; Travis, R.; Aiello, R.; Williamson, E.; Veenstra-VanderWeele, J.; Krishnaswami, S.; Jerome, R. y Warren, Z. (2014), *Therapies for Children With Autism Spectrum Disorder: Behavioral Interventions Update*, Internet (vid. pág. 16).
- Welles, A. P.; Xu, X.; Santee, W. R.; Looney, D. P.; Buller, M. J.; Potter, A. W. y Hoyt, R. W. (2018), «Estimation of core body temperature from skin temperature, heat flux, and heart rate using a Kalman filter», *Computers in Biology and Medicine* **99**(April), págs. 1-6, DOI: [10.1016/j.combiomed.2018.05.021](https://doi.org/10.1016/j.combiomed.2018.05.021) (vid. pág. 27).
- Wilkinson, I. B.; MacCallum, H.; Flint, L.; Cockcroft, J. R.; Newby, D. E. y Webb, D. J. (2000), «The influence of heart rate on augmentation index and central arterial pressure in humans», *Journal of Physiology* **525**(1), págs. 263-270, DOI: [10.1111/j.1469-7793.2000.t01-1-00263.x](https://doi.org/10.1111/j.1469-7793.2000.t01-1-00263.x) (vid. pág. 29).
- Wong, M. S.; Wang, T.; Ho, H. C.; Kwok, C. Y. T.; Lu, K. y Abbas, S. (2018), «Towards a Smart City: Development and Application of an Improved Integrated Environmental Monitoring System», *Sustainability* **10**(3), DOI: [10.3390/su10030623](https://doi.org/10.3390/su10030623) (vid. pág. 20).
- Yu, K. H.; Zhang, C.; Berry, G. J.; Altman, R. B.; Ré, C.; Rubin, D. L. y Snyder, M. (2016), «Predicting non-small cell lung cancer prognosis by fully automated microscopic pathology image features», *Nature Communications* **7**, págs. 1-10, DOI: [10.1038/ncomms12474](https://doi.org/10.1038/ncomms12474) (vid. pág. 22).
- Zhang, Y.; Song, S.; Vullings, R.; Biswas, D.; Simões-Capela, N.; Van Helleputte, N.; Van Hoof, C. y Groenendaal, W. (2019), «Motion artifact reduction for wrist-worn photoplethysmograph sensors based on different wavelengths», *Sensors (Switzerland)* **19**(3), DOI: [10.3390/s19030673](https://doi.org/10.3390/s19030673) (vid. pág. 126).
- Zhu, L.; Kan, C.; Du, Y. y Du, D. (2019), «Heart Rate Monitoring during Physical Exercise from Photoplethysmography Using Neural Network», *IEEE Sensors Letters* **3**(1), págs. 1-4, DOI: [10.1109/LENS.2018.2878207](https://doi.org/10.1109/LENS.2018.2878207) (vid. pág. 126).

Zinkhan, M. y Kantelhardt, J. W. (2016), «Sleep Assessment in Large Cohort Studies with High-Resolution Accelerometers», *Sleep Medicine Clinics* **11**(4), Technology to Assess Sleep, págs. 469-488, DOI: <https://doi.org/10.1016/j.jsmc.2016.08.006> (vid. pág. 33).