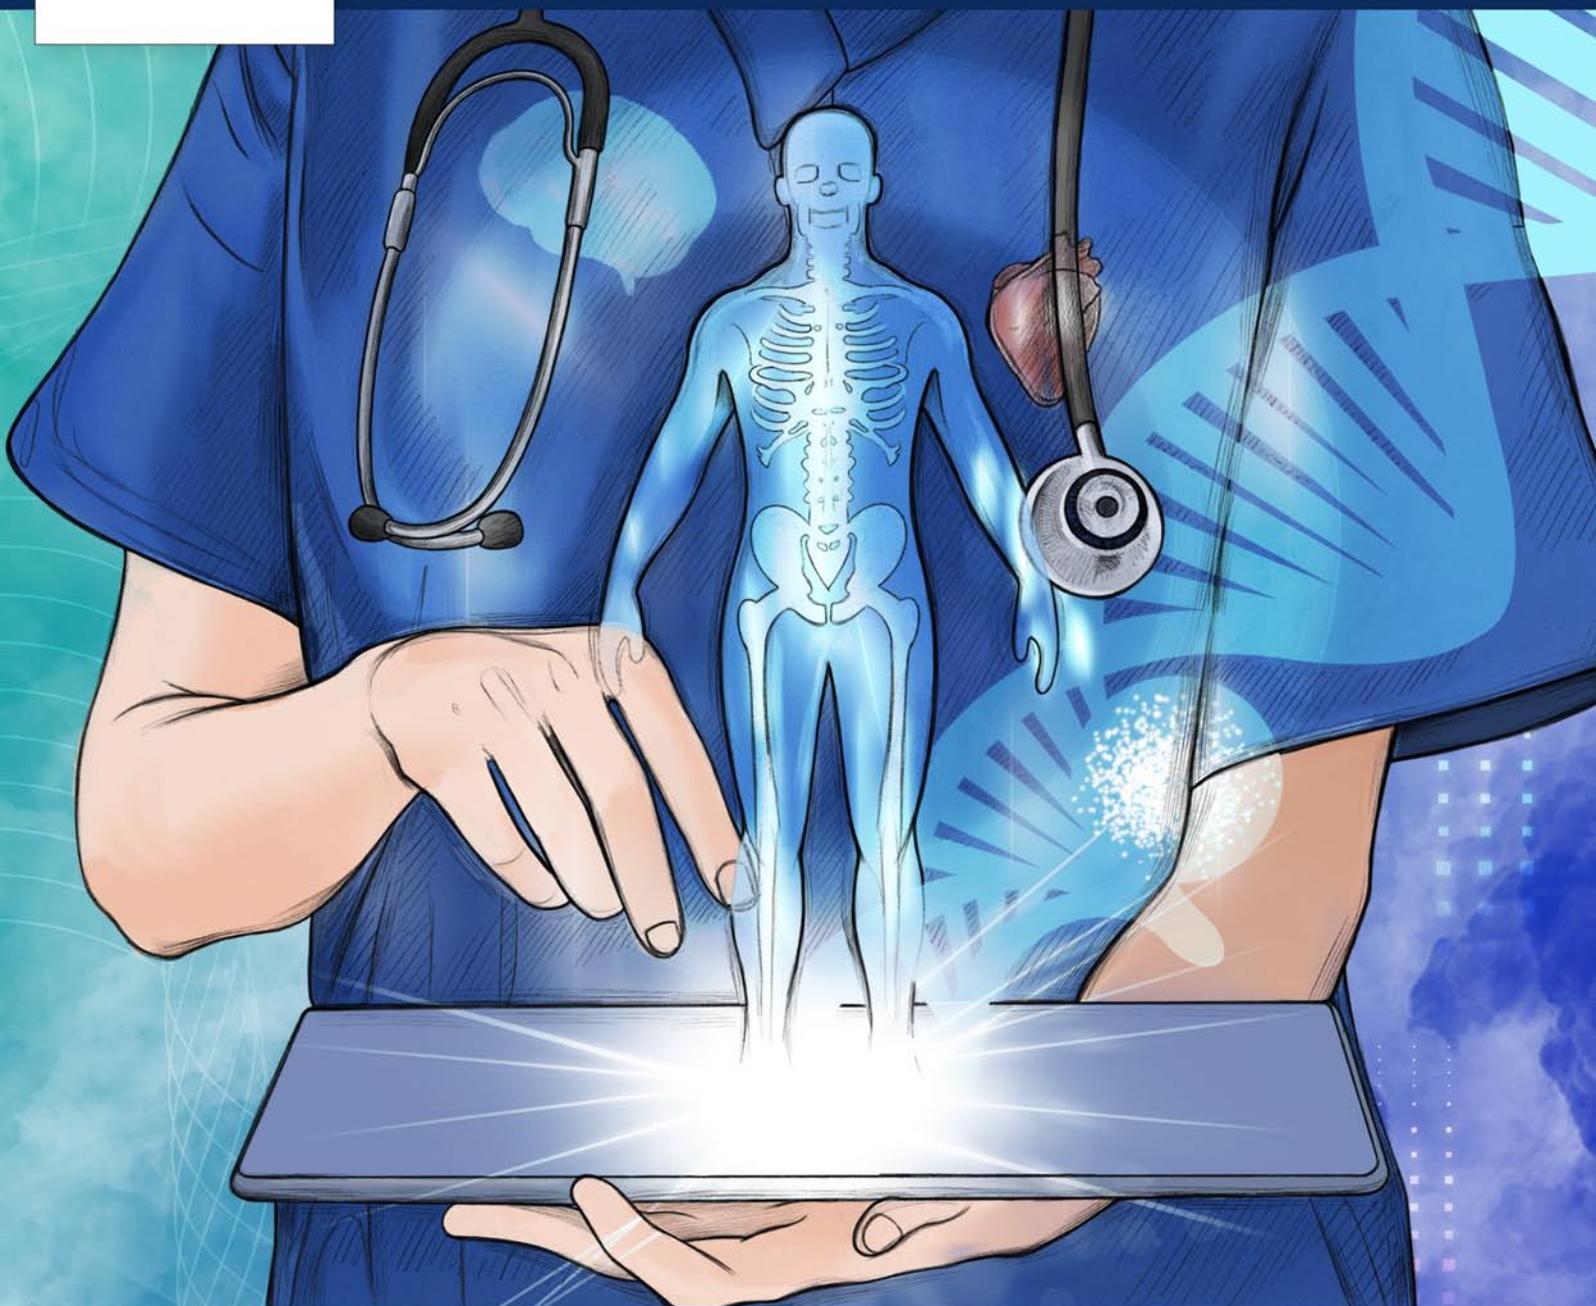




CASEIB
2021
XXXIX

XXXIX CONGRESO ANUAL DE LA SOCIEDAD ESPAÑOLA DE INGENIERÍA BIOMÉDICA



LIBRO DE ACTAS

ORGANIZAN:



UNIVERSIDAD
POLITÉCNICA
DE MADRID





CASEIB
2021
XXXIX

Congreso Anual
de la Sociedad
Española de
Ingeniería
Biomédica

LIBRO DE ACTAS

Madrid, 25 y 26 de noviembre de 2021

XXXIX Congreso Anual de la Sociedad Española de Ingeniería Biomédica

Presidente del Comité Organizador:

Enrique J. Gómez Aguilera

Secretaria del Comité Organizador:

Patricia Sánchez González

Editores:

Paloma Chausa Fernández

Gema García Sáez

Enrique J. Gómez Aguilera

M. Elena Hernando Pérez

Patricia Sánchez González

Diseño de portada:

Sandra Martínez

ISBN: 978-84-09-36054-3



Libro de Actas del XXXIX Congreso Anual de la Sociedad Española de Ingeniería Biomédica
Se distribuye bajo una licencia de Creative Commons Reconocimiento-NoComercial-Sin Obra
Derivada 4.0 Internacional.

COMITÉ CIENTÍFICO

Presidente

Enrique J. Gómez
Aguilera
*Universidad Politécnica
de Madrid*

Secretaria

M. Elena Hernando
Pérez
*Universidad Politécnica
de Madrid*

Co-Secretaria

Patricia Sánchez
González
*Universidad Politécnica
de Madrid*

Vocales

Begoña Acha Piñero. *Universidad de
Sevilla*

Roberto Hornero Sánchez. *Universidad
de Valladolid*

Raúl Alcaraz Martínez. *Universidad de
Castilla-La Mancha*

Raimon Jané Campos. *Universidad
Politécnica de Cataluña*

Erik Alonso. *Universidad del País Vasco*

Pablo Laguna Lasasa. *Universidad de
Zaragoza*

Elisabete Aramendi Ecenarro.
Universidad del País Vasco

María Jesús Ledesma. *Universidad
Politécnica de Madrid*

José Luis Arce Diego. *Universidad de
Cantabria*

Maite Mujika Garmendia. *CEIT-TECNUN,
San Sebastián*

M^a Gloria Bueno García. *Universidad de
Castilla-La Mancha*

Jesús Poza Crespo. *Universidad de
Valladolid*

Manuel Desco Menéndez. *Universidad
Carlos III de Madrid*

Gema Prats Boluda. *Universidad
Politécnica de Valencia*

Félix Fanjul Vélez. *Universidad de
Cantabria*

Javier Reina Tosina. *Universidad de
Sevilla*

Javier García Casado. *Universidad
Politécnica de Valencia*

Ana de los Reyes Guzmán. *Servicio de
Salud de Castilla-La Mancha*

María García Gadañón. *Universidad de
Valladolid*

José Joaquín Rieta Ibáñez. *Universidad
Politécnica de Valencia*

Beatriz F. Giraldo Giraldo. *Universidad
Politécnica de Cataluña*

Isabel Román Martínez. *Universidad de
Sevilla*

ÍNDICE DE SESIONES CIENTÍFICAS

Jueves 25 de Noviembre de 2021, a las 11:45

Premios FENIN para alumnos de Grado en Ingeniería Biomédica

Moderador: D. Roberto Hornero

Implementing an optical tweezers setup as a microrheology technique to study the mechanical properties of the cytoplasm	2
Diseño e implementación de algoritmos de machine learning para la caracterización objetiva del temblor patológico mediante señales cinemáticas y fisiológicas	6
Monitorización longitudinal de la compliancia pulmonar basada en la TIE en pacientes infectados por COVID-19	10
A Virtual Reality Application for Training Medical Students in a Pneumothorax Procedure	14
Reconstrucción en 3D del microambiente inmunológico de tumores de cáncer pancreático	18
Estudio de la arquitectura temporal de la actividad neuronal en la demencia por enfermedad de Alzheimer mediante técnicas de conectividad funcional dinámica	22
Optimización de hidrogeles inyectables y liberación de factores de crecimiento hepático.....	26
Discovering the drivers of aberrant splicing in cancer	30
Análisis de texturas como ayuda al diagnóstico neurooncológico en imágenes de resonancia magnética	34
Análisis de las variables biomecánicas para el estudio del índice de ruptura de la Triple A	38
SleepBCI: a platform for memory enhancement during sleep based on automatic scoring	42
Telerehabilitation of post-stroke motor impairment	46

Premios José María Ferrero Corral

Moderadora: Dña. Elisabete Aramendi

Prediction of short-term survival in glioblastoma patients with total tumor resection from multimodal pre-surgical MRI images using machine learning	51
Evaluación de la robustez de la red neuronal funcional en la enfermedad de Alzheimer	55
Análisis de las alteraciones en la organización jerárquica de la actividad neuronal debidas a la enfermedad de Alzheimer	59
Modelo de deep learning basado en la combinación de redes neuronales convolucionales y recurrentes para clasificar eventos de apnea e hipopnea mediante la señal de oximetría	63
Surgical phase recognition for non-intrusive surgical skills' assessment in educational contexts based in speech and video	67
La importancia dinámica como indicador de comportamiento de hub en la región parietal de la red neuronal por defecto	71
Sub-surface laser engraving application for hexagonal SiPM	75
Methodologies for the quantification and classification of nuclear medicine neuroimaging for clinical decision support	79
La importancia de la aurícula izquierda en la alteración del sustrato auricular tras ablación por catéter de Fibrilación Auricular Paroxística	83
Optimización preoperatoria de la configuración de los electrodos de estimulación con un modelo 3D de médula espinal personalizado al paciente	87
P-Wave detection using latent spaces from autoencoders and domain description classifiers	91
“Time-Warping” ponderado sobre la onda T para reducir el impacto de errores de delineación: implicaciones clínicas	95
Diseño e implementación de un sistema de simulación para el manejo de la fractura de pelvis	99
Cambio de FiO2 como alternativa al gadolinio para estudios de perfusión cerebral por resonancia magnética	103
Análisis de OCTA (angiografía por tomografía de coherencia óptica) mediante redes neuronales convolucionales para el diagnóstico de esclerosis múltiple	107

Desarrollo y validación de los bucles de control para las interfaces hápticas de un simulador de silla de ruedas manual	111
Modificación de un modelo de miocito ventricular humano para representar el papel de los canales SK en insuficiencia cardiaca	115
Análisis del impacto combinado del grupo sanguíneo y los antígenos leucocitarios humanos en la supervivencia del trasplante renal en Andalucía	119
Machine learning algorithms to predict adherence to treatment pathways in secondary prevention of patients with acute coronary syndrome	123
Deep learning-based segmentation of head and neck organs on CT for radiotherapy treatment: lessons learned with clinical data	127
Propuesta de modelos predictivos en salud mental para la personalización de terapias de rehabilitación en pacientes con adicción a la cocaína	131
Visualización de estudios preoperatorios en forma de nube de puntos volumétrica en dispositivos de realidad mixta	135
Evaluación de la calidad en registros electrocardiográficos para diagnósticos automáticos fiables mediante aprendizaje profundo y aumento de datos	139
Design, manufacture and validation of customized surgical guides for total knee replacement	143
Análisis paso a paso de registros de ablación por catéter en fibrilación auricular paroxística	147
Evaluación del riesgo de hipertensión a partir de registros fotopletimográficos utilizando clasificadores de deep learning	151
Diferencias entre patrones de ondas P y ondas de activación local del seno coronario durante ablación por catéter de fibrilación auricular paroxística	155
Reconocimiento automático de posiciones radiográficas en radiología	159
EEG-InceptionGen: una red convolucional de propósito general para la clasificación de señales EEG	163
Procesamiento de TAC de tórax para su uso en simulaciones de tomosíntesis.....	167
Electrophysiological modelling of left ventricle with heterogeneous scar to assess inducibility of reentry circuits	171
Inclusión de compensación de movimiento en un esquema deep learning basado en modelo para la reconstrucción de imágenes de cine cardíaco	175
Reconstrucción de imágenes para tomosíntesis de tórax mediante aprendizaje profundo	179
A simplified methodology to measure gait spatio-temporal parameters using low-cost inertial sensors	183

Wearable technology for predicting the quality of surgical performance and workload in laparoscopic surgery: preliminary results	187
Citometría de microflujo para estudios bacterianos	189
Información a priori obtenida con aprendizaje profundo para su uso en algoritmo de reconstrucción iterativo	193
Método para la caracterización de la señal de presión arterial invasiva continua durante la reanimación cardiopulmonar	197
Interfaz para el estudio del “jitter” neuromuscular	201
An immersive virtual reality training system for paediatric stroke code medical training	205

Premios José María Ferrero Corral

Jueves 25 de Noviembre de 2021, 15:00

Modelo de *deep learning* basado en la combinación de redes neuronales convolucionales y recurrentes para clasificar eventos de apnea e hipopnea mediante la señal de oximetría

F. Vaquerizo Villar^{1,3}, D. Álvarez González^{1,2,3}, G.C. Gutiérrez Tobal^{1,3}, J. Jiménez García¹, C. A. Arroyo Domingo², F. del Campo^{2,3}, R. Hornero^{1,3}

¹ Grupo de Ingeniería Biomédica, Universidad de Valladolid, Valladolid, España, fernando.vaquerizo@gib.tel.uva.es

² Servicio de Neumología, Hospital Universitario Río Hortega, Valladolid, España, fsas@telefonica.net

³ Centro de Investigación Biomédica en Red en Bioingeniería, Biomateriales y Nanomedicina, (CIBER-BBN), España

Resumen

En este estudio se evalúa un clasificador automático de eventos respiratorios mediante la aplicación de una arquitectura de deep learning sobre la señal de saturación de oxígeno en sangre (SpO₂) en adultos diagnosticados con apnea obstructiva del sueño (AOS). Para ello, se han analizado 398 registros de SpO₂ de sujetos adultos. Se ha diseñado una arquitectura CNN+RNN compuesta por: (i) una red neuronal convolucional (CNN), que permite extraer características de los eventos respiratorios, y (ii) una red neuronal recurrente (RNN), encargada de modelar la distribución temporal de los eventos respiratorios durante el sueño. Esta arquitectura recibe a su entrada secuencias de segmentos de 30 s de la señal de SpO₂, clasificando cada segmento en 3 categorías: respiración normal, apnea e hipopnea. A continuación, se empleó un modelo de regresión para estimar el índice de apnea-hipopnea (IAH) de cada paciente. La arquitectura CNN+RNN propuesta alcanzó una precisión global del 80% y un Cohen's kappa de tres clases igual a 0.53, superando a una arquitectura CNN convencional. El IAH obtenido a partir del modelo CNN+RNN alcanzó un alto rendimiento diagnóstico, mostrando un Cohen's kappa de 0.649, así como precisiones del 90.8% y 89.2% para los umbrales del IAH de 15 y 30 eventos por hora. Estos resultados sugieren que la combinación de CNN+RNN permite extraer información sobre la distribución temporal de los eventos respiratorios, que por sí solas las CNN no pueden discernir, siendo así una herramienta útil en la detección de la AOS a partir de la señal de oximetría.

1. Introducción

La apnea obstructiva del sueño (AOS) se ha convertido en los últimos años en un importante problema sanitario a nivel mundial [1]. La AOS se caracteriza por la repetición recurrente de eventos de ausencia total (apnea) o parcial (hipopnea) de respiración durante el sueño, que derivan en una arquitectura del sueño fragmentada y no reparadora [2]. Aunque la prevalencia de la AOS es muy elevada en la población adulta (9%-38%), se trata de una enfermedad infradiagnosticada, lo cual contribuye a un mayor riesgo de alteraciones cardiovasculares, metabólicas y psiquiátricas, como la hipertensión, accidentes cerebrovasculares, diabetes y depresión [1].

A pesar de ser la técnica de referencia en el diagnóstico de la AOS, la polisomnografía (PSG) nocturna presenta importantes limitaciones. Se trata de una prueba costosa, incómoda para el paciente y de elevada complejidad, tanto en la realización como en su posterior interpretación, lo cual puede derivar en errores e inconsistencias en el

diagnóstico [3]. Ante estas limitaciones, múltiples investigaciones se han centrado en el uso de herramientas automáticas aplicadas a la detección de la AOS mediante un conjunto reducido de señales cardiorrespiratorias. Entre ellas, destaca el análisis de la señal de saturación de oxígeno en sangre (SpO₂) procedente de la oximetría nocturna, debido a su facilidad de adquisición e interpretación [4].

Diferentes estudios centrados en la señal de SpO₂ han abordado la detección automática de eventos respiratorios (apneas e hipopneas) y el diagnóstico automático de la AOS utilizando metodologías de *feature engineering*, basadas en la extracción y selección de características [4], [5]. Sin embargo, estas metodologías requieren determinar, *a priori*, las características a extraer de la señal, lo cual limita su capacidad para aprovechar toda la información contenida en el registro de SpO₂ relacionada con los eventos respiratorios. Esta limitación se puede solventar mediante los métodos de *deep learning*, que son capaces de aprender de manera automática las particularidades inherentes de los datos mediante el uso de arquitecturas multicapa con múltiples niveles de representación [6].

Estudios recientes han demostrado la superioridad de las técnicas de *deep learning* sobre los métodos de *feature engineering* para analizar señales cardiorrespiratorias en la detección de eventos apnéicos [7]. Sin embargo, los estudios centrados en el análisis de la señal de SpO₂ han abordado únicamente la detección automática de eventos respiratorios frente a episodios de respiración normal, sin diferenciar entre apneas e hipopneas [8]–[10]. Además, estos estudios han utilizado redes neuronales convolucionales (CNNs) que, a pesar de ser útiles para aprender las características de los eventos respiratorios, no consideran su distribución temporal durante el sueño [6], [11]. En cambio, las redes neuronales recurrentes (RNNs) aprenden las dependencias temporales de los datos, permitiendo así mejorar la detección de secuencias de eventos de apnea e hipopnea [11], [12], que en muchas ocasiones se presentan agrupados en forma de *clusters*.

Por tanto, el presente estudio parte de la hipótesis de que una arquitectura de *deep learning* basada en una combinación de CNN y RNN (CNN+RNN) podría extraer nueva información presente en la señal de SpO₂ capaz de mejorar la identificación y diferenciación de eventos de

apnea e hipopnea. Consecuentemente, el objetivo principal del estudio consiste en diseñar y evaluar un modelo de *deep learning* para la clasificación automática de eventos respiratorios basado en una arquitectura CNN+RNN aplicada a la señal de SpO₂. Además, se propone como objetivo secundario evaluar la utilidad del modelo CNN+RNN para la estimación del índice de apnea-hipopnea (IAH), que es el parámetro clínico para el diagnóstico de la AOS.

2. Sujetos y señales

En este estudio se ha analizado una población compuesta por 398 sujetos adultos, donde todos fueron diagnosticados con AOS (IAH \geq 5 e/h). Todos ellos fueron remitidos a la unidad del sueño del Hospital Universitario Río Hortega (Valladolid, España), donde se les realizó la PSG. El protocolo del estudio fue aprobado por el Comité Ético y de Investigación con medicamentos (CEIm 47/16).

De acuerdo con las reglas de la Academia Americana de Medicina del Sueño, se ha considerado como evento de apnea una disminución del 90% en el flujo aéreo (FA) durante al menos 10 segundos. Asimismo, se ha considerado como hipopnea una disminución del FA de al menos un 30%, con una duración de 10 segundos o más, y que esté acompañada de una desaturación de oxígeno igual o superior al 3% y/o por un micro-despertar [2]. A partir de estas anotaciones, se obtuvo el IAH de cada sujeto como el número de eventos de apnea e hipopnea por hora de sueño (e/h). A partir del IAH estimado, se evaluó la capacidad del modelo para diagnosticar AOS leve (5 \leq IAH $<$ 15 e/h), AOS moderado (15 \leq IAH $<$ 30 e/h) y AOS severo (IAH \geq 30 e/h).

Los registros de SpO₂ se obtuvieron durante la PSG a una frecuencia de muestreo de 16 Hz y posteriormente se remuestrearon a una frecuencia de 1 Hz, que ha demostrado ser suficiente para caracterizar la señal de SpO₂ a la vez que permite reducir el coste computacional [12]. Cada señal se dividió en segmentos de 30 s y cada segmento se etiquetó como respiración normal (N), apnea (A) o hipopnea (H) según las anotaciones proporcionadas por los especialistas al analizar la PSG. La población fue distribuida de manera consecutiva en tres grupos: entrenamiento (199 sujetos, 50%), empleado para entrenar la arquitectura CNN+RNN; validación (79 sujetos, 20%), utilizado para la optimización de hiperparámetros, y test (120 sujetos, 30%), empleado para evaluar la metodología propuesta. La tabla 1 muestra las características clínicas y polisomnográficas de la población bajo estudio.

3. Metodología

3.1. Arquitectura CNN+RNN

La figura 1 muestra la arquitectura *deep learning* propuesta, que consiste en la combinación de una CNN y una RNN. La sección de entrada consiste en una secuencia de 100 épocas consecutivas de 30 s de la señal de SpO₂. La arquitectura propuesta procesa de manera independiente cada época con una capa de distribución temporal que contiene una CNN. La CNN está compuesta por 6 bloques convolucionales con el objetivo de aprender las características de los eventos de apnea e hipopnea que contiene cada época. Cada uno de estos bloques está

	Todos	Entrenamiento	Validación	Test
Características de los pacientes en cada subconjunto de datos				
Sujetos (n)	398	199	78	120
Edad (años)	56 [47-65]	56 [47-64]	56 [47-67]	55 [44-65]
Varones (n)	278 (69.9%)	144 (72.4%)	59 (74.6%)	75 (62.5%)
IMC (kg/m²)	29.1 [26.1-33.1]	29.4 [26.0-33.5]	28.9 [26.8-31.7]	29.2 [25.6-34.0]
IAH (e/h)	35.0 [17.3-59.4]	33.2 [15.9-59.7]	35.0 [17.3-59.4]	36.2 [18.3-61.4]
Número y tipo de eventos en cada subconjunto de datos				
Normal (n)	250669 (72.5%)	127292 (73.2%)	49932 (72.5%)	73445 (71.3%)
Apnea (n)	40838 (11.8%)	20174 (11.6%)	7972 (11.6%)	12692 (12.3%)
Hipopnea (n)	54165 (15.7%)	26350 (15.2%)	10989 (15.9%)	16826 (16.4%)

Los datos se presentan como mediana [rango intercuartil] o n (%). IMC: Índice de masa corporal; IAH: índice de apnea-hipopnea

Tabla 1. Datos clínicos y polisomnográficos de los sujetos

formado por una etapa convolucional, que extrae los mapas de características mediante 64 filtros de tamaño 5, una etapa de normalización (*batch normalization*) y una función de activación ReLU (*Rectified Linear Unit*) [6]. Después del último bloque convolucional, la última etapa de la CNN, *flattening*, convierte los mapas de características 2D en series de datos 1D [6].

La capa de distribución temporal CNN es procesada mediante una RNN, para así aprender la distribución

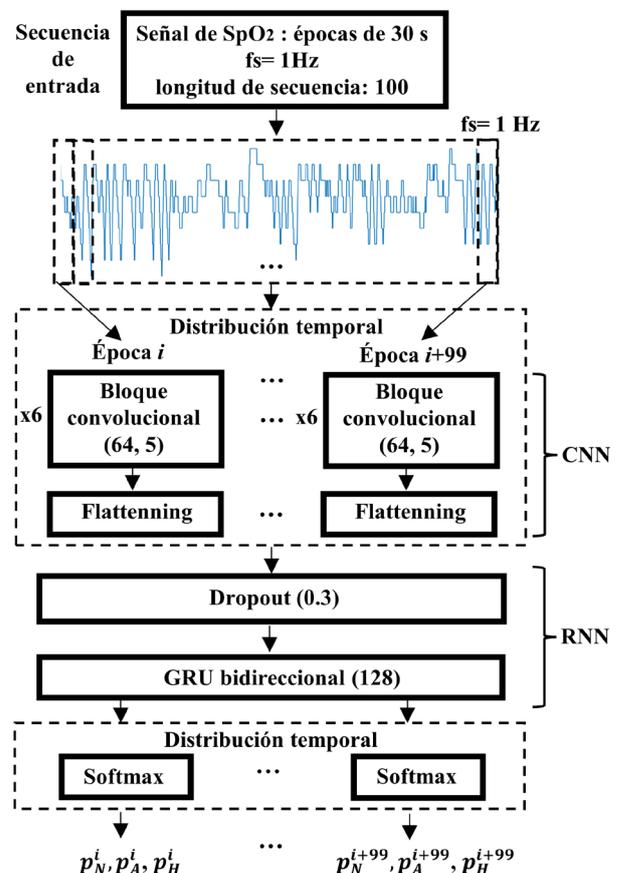


Figura 1. Arquitectura de *deep learning* basada en una combinación de CNN y RNN (CNN+RNN).

temporal de los eventos respiratorios que ocurren durante la secuencia. En primer lugar, una capa de regularización (*dropout*) se encarga de eliminar conexiones entre elementos de la red con una probabilidad de 0.3 para reducir el sobreentrenamiento [6]. A continuación, una capa recurrente bidireccional compuesta por 128 celdas de tipo GRU (*gated recurrent units*) se encarga de modelar la dependencia temporal de la secuencia de épocas de entrada, decidiendo qué información debe ser retenida y cuál debe ser olvidada de la red [6]. Finalmente, una capa de distribución temporal que contiene una función de activación *softmax* es utilizada para obtener la probabilidad de cada época i de la secuencia de ser un evento de apnea (p_A^i), hipopnea (p_H^i) o respiración normal (p_N^i).

La arquitectura CNN+RNN se ha implementado en la librería *Keras*. La inicialización de pesos de la arquitectura se hizo con el método *He-normal*. El entrenamiento se llevó a cabo con la función de pérdida *categorical cross-entropy* y el algoritmo Adam, con una tasa de aprendizaje inicial de 0.0001, para la optimización de pesos [6].

3.2. Estimación del IAH

A partir de las probabilidades de salida del modelo CNN+RNN para cada segmento de 30 s de la señal de SpO₂, se ha obtenido el IAH de cada sujeto. Para ello, se han considerado como evento apneico ($y^i = 1$) aquellos segmentos donde es mayor la probabilidad de apnea o hipopnea que de respiración normal:

$$y^i = \begin{cases} 1, & p_A^i > p_N^i \text{ o } p_H^i > p_N^i \\ 0, & \text{otros} \end{cases} \quad (1)$$

A continuación, dado un sujeto con N segmentos de 30 s de la señal de SpO₂, el IAH es estimado mediante regresión lineal, cuyos coeficientes β (pendiente) y ε (sesgo) son optimizados en el conjunto de validación [12]:

$$IAH = (\beta \cdot \sum_{i=1}^N \frac{y^i}{N}) + \varepsilon \quad (2)$$

3.3. Comparación con una CNN convencional

Se ha implementado una arquitectura de *deep learning* clásica basada en CNN para comparar el rendimiento diagnóstico del modelo CNN+RNN. La sección de entrada de esta arquitectura consiste en una época de 30 s de la señal de SpO₂. A continuación, la arquitectura CNN consta de 6 bloques convolucionales, una capa de *flattening* y una unidad de activación *softmax*, que permiten obtener las probabilidades de salida para esa época (p_A^i , p_H^i y p_N^i). A partir de las probabilidades p_A^i , p_H^i y p_N^i obtenidas para cada época, se ha estimado el IAH de cada sujeto a través de (1) y (2).

3.4. Análisis estadístico

La concordancia de las arquitecturas CNN+RNN y CNN en la clasificación automática de eventos respiratorios se evaluó por medio de la matriz de confusión (de 3 clases), la precisión global (suma de la diagonal principal) y el coeficiente *kappa* (κ). Además, se calculó, para ambas arquitecturas, el número total de eventos de apnea, hipopnea y apnea+hipopnea de cada sujeto y se compararon estos valores con los obtenidos durante la PSG

mediante el coeficiente de correlación intraclase (CCI). Asimismo, el rendimiento diagnóstico del IAH obtenido por el modelo CNN+RNN se evaluó en términos de precisión global, κ , sensibilidad (S), especificidad (E), valor predictivo positivo y negativo (VPP y VPN), razón de verosimilitud positiva y negativa (LR+ y LR-) y precisión (P).

4. Resultados

4.1. Clasificación orientada a eventos

La Figura 2 muestra la matriz de confusión en el grupo de test de los modelos CNN+RNN y CNN para clasificar automáticamente eventos respiratorios. Es importante destacar que el modelo CNN+RNN clasificó correctamente el 80.0% (83222/104043) de las épocas de 30 s, con un κ de 0.53, mientras que el modelo CNN alcanzó una precisión global del 78.8% (82087/104043) y un κ de 0.48. Además, el modelo CNN+RNN superó al modelo CNN en el CCI correspondiente a los eventos de apnea (0.931 vs 0.893), hipopnea (0.689 vs 0.543) y apnea+hipopnea (0.921 vs 0.851).

4.2. Clasificación orientada a sujetos

La figura 3 muestra la matriz de confusión del IAH estimado por el modelo CNN+RNN en el grupo de test. El modelo CNN+RNN alcanzó una precisión global del 80.0% (96/120) a la hora de determinar el grupo de severidad de la AOS, así como un κ de 0.65. Asimismo, se obtuvieron precisiones del 90.8% y 89.2% en el conjunto de test para los umbrales de 15 e/h y 30 e/h, respectivamente, como se puede ver en la tabla 2.

		CNN+RNN			CNN			
PSG	N	68878 0.93	1773 0.02	3755 0.05	N	69741 0.94	1621 0.02	3044 0.04
	A	2807 0.22	7755 0.61	2202 0.17	A	3511 0.28	6820 0.53	2433 0.19
	H	6750 0.40	3534 0.21	6589 0.39	H	8654 0.51	2763 0.16	5456 0.32
		N	A	H	N	A	H	

Figura 2. Matriz de confusión de las arquitecturas CNN+RNN y CNN en la clasificación orientada a eventos en el grupo de test.

		CNN+RNN		
PSG	1	18 0.72	7 0.28	0 0.00
	2	4 0.17	14 0.58	6 0.25
	3	0 0.00	7 0.10	64 0.90
		1	2	3

Figura 3. Matriz de confusión de la arquitectura CNN+RNN en la clasificación orientada a sujetos en el grupo de test. 1: AOS leve ($5 \leq IAH < 15$ e/h); 2: AOS moderado ($15 \leq IAH < 30$ e/h); 3: AOS severo ($IAH \geq 30$ e/h).

Método	IAH (e/h)	S (%)	E (%)	VPP (%)	VPN (%)	LR+	LR-	P (%)
CNN+RNN	15	95.8	72.0	92.9	81.8	3.42	0.06	90.8
	30	90.1	87.8	91.4	86.0	7.36	0.11	89.2

Tabla 2. Rendimiento diagnóstico del modelo CNN+RNN en el grupo de test para los puntos de corte de 15 y 30 e/h.

5. Discusión y conclusiones

En este estudio se ha evaluado un clasificador automático de eventos respiratorios (apnea, hipopnea y respiración normal) mediante la aplicación de una arquitectura novedosa de *deep learning* compuesta por una combinación CNN+RNN sobre la señal de SpO₂. El modelo CNN+RNN propuesto ha alcanzado una concordancia notable para la clasificación de eventos de apnea e hipopnea, superando a una red CNN convencional. Por tanto, la información sobre la dependencia temporal de los datos proporcionada por la RNN permite mejorar la detección de secuencias de eventos de apnea e hipopnea. En las matrices de confusión de la figura 2, se observa cómo la arquitectura CNN+RNN ha detectado con mayor precisión los eventos de apnea (61%) que los eventos de hipopnea (39%). Esto puede ser debido a la presencia de hipopneas asociadas a un micro-despertar que no están ligadas a ningún cambio en la señal de SpO₂ [2]. En la clasificación orientada a sujetos, el IAH estimado por el modelo CNN+RNN mediante un procedimiento basado en ponderación y regresión lineal ha obtenido un elevado rendimiento diagnóstico, con precisiones cercanas al 90% en los puntos de corte de 15 y 30 e/h.

Estudios previos han demostrado la utilidad de los métodos de *deep learning* para detectar automáticamente eventos respiratorios a partir de señales biomédicas, superando a los métodos clásicos de *feature engineering* [7]. Dentro de estos estudios, Vaquerizo-Villar *et al.* [8] y Mostafa *et al.* [9], [10] aplicaron redes CNN a segmentos de 60 s de la señal de SpO₂ para detectar eventos respiratorios frente a episodios de respiración normal, alcanzando precisiones en un rango 85%-95%. En nuestro estudio, se ha obtenido una precisión de 2 clases (normal vs. apnea/hipopnea) en ese rango (85.5%) con un tamaño de segmento de 30 s, que es más adecuado para detectar *clusters* de eventos respiratorios [2]. Además, en el presente estudio se aborda por primera vez la diferenciación entre apneas e hipopneas mediante una arquitectura CNN+RNN.

Este estudio presenta ciertas limitaciones. En primer lugar, la base de datos empleada en este trabajo no incluye sujetos no-AOS (IAH<5 e/h). La inclusión de estos sujetos sería útil para medir el rendimiento diagnóstico de la arquitectura CNN+RNN en sueño no patológico. Además, la aplicación de técnicas *explainable Artificial Intelligence* podría ayudar a identificar las características de la señal de oximetría extraídas por el modelo CNN+RNN que están relacionadas con los eventos de apnea y de hipopnea, así como las diferencias entre ellas.

En resumen, una arquitectura de *deep learning* basada en una combinación de CNN y RNN ha demostrado ser muy útil para la clasificación automática de eventos de apnea e hipopnea a partir de la señal de SpO₂, superando a la arquitectura CNN convencional. Además, el modelo

propuesto ha alcanzado un elevado rendimiento diagnóstico para los umbrales de severidad de la AOS de 15 y 30 e/h. Estos resultados sugieren que las arquitecturas CNN+RNN pueden ser utilizadas para extraer información adicional sobre la distribución temporal de los eventos de apnea e hipopnea la señal de oximetría en la ayuda a la detección automática de la AOS.

Agradecimientos

Este estudio ha sido financiado por el Ministerio de Ciencia e Innovación-Agencia Estatal de Investigación (MICN-AEI) y FEDER (PID2020-115468RB-I00 y RTC-2017-6516-1), por el CIBER-BBN (ISCIII), por la Sociedad Española de Neumología y Cirugía Torácica (SEPAR 649/2018) y por la Sociedad Española de Sueño (Beca de Investigación SES 2019). F. Vaquerizo Villar cuenta con una ayuda para la Formación de Profesorado Universitario del Ministerio de Educación, Cultura y Deporte (FPU16/02938). D. Álvarez es beneficiario de una ayuda Ramón y Cajal (RYC2019-028566-I) del MICN-AEI y el Fondo Social Europeo. J. Jiménez cuenta con un contrato predoctoral concedido por la Universidad de Valladolid.

Referencias

- [1] C. V. Senaratna *et al.*, "Prevalence of obstructive sleep apnea in the general population: A systematic review," *Sleep Med. Rev.*, vol. 34, pp. 70–81, 2017.
- [2] R. B. Berry *et al.*, "Rules for scoring respiratory events in sleep: update of the 2007 AASM manual for the scoring of sleep and associated events: deliberations of the sleep apnea definitions task force of the American Academy of Sleep Medicine," *J. Clin. sleep Med.*, vol. 8, no. 5, p. 597, 2012.
- [3] S. M. *et al.*, "Sleep apnea: a review of diagnostic sensors, algorithms, and therapies," *Physiol. Meas.*, vol. 38, no. 9, pp. R204–R252, 2017.
- [4] F. del Campo, *et al.*, "Oximetry use in obstructive sleep apnea," *Expert Rev. Respir. Med.*, vol. 12, no. 8, pp. 665–681, 2018.
- [5] M. B. Uddin, *et al.*, "Classification methods to detect sleep apnea in adults based on respiratory and oximetry signals: A systematic review," *Physiol. Meas.*, vol. 39, no. 3, 2018.
- [6] I. Goodfellow, *et al.*, *Deep Learning*. MIT Press, 2016.
- [7] S. S. Mostafa, F. Mendonça, A. G. Ravelo-García, and F. Morgado-Dias, "A systematic review of detecting sleep apnea using deep learning," *Sensors (Switzerland)*, vol. 19, no. 22, pp. 1–26, 2019.
- [8] F. Vaquerizo-Villar *et al.*, "Convolutional Neural Networks to Detect Pediatric Apnea- Hypopnea Events from Oximetry," in *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2019, pp. 3555–3558.
- [9] S. S. Mostafa, *et al.*, "Greedy based convolutional neural network optimization for detecting apnea," *Comput. Methods Programs Biomed.*, vol. 197, p. 105640, 2020.
- [10] S. S. Mostafa, *et al.*, "Multi-Objective Hyperparameter Optimization of Convolutional Neural Network for Obstructive Sleep Apnea Detection," *IEEE Access*, vol. 8, pp. 129586–129599, 2020.
- [11] S. Nikkonen *et al.*, "Automatic Respiratory Event Scoring in Obstructive Sleep Apnea Using a Long Short-Term Memory Neural Network," *IEEE J. Biomed. Heal. Informatics*, vol. 25, no. 8, pp. 2917–2927, 2021.
- [12] F. Vaquerizo-Villar *et al.*, "A convolutional neural network architecture to enhance oximetry ability to diagnose pediatric obstructive sleep apnea," *IEEE J. Biomed. Heal. Informatics*, vol. 25, no. 8, 2021.

ÍNDICE DE AUTORES

A

Abella M	159, 167, 179, 193
Acosta O	127
Aja-Fernández S	51
Albajar Sigalés A	2
Alberdi Aramendi A	10
Alberola-López C	51, 175
Alcaraz Martínez R	83, 139, 147, 151, 155
Almagro-Pérez C	18
Álvarez González D	63
Álvarez I	42
Añorbe de Frutos A	30
Aramendi Ecenarro E	197
Arroyo Domingo CA	63
Atienza Vicente CM	143

B

Barea R	107
Barrenechea M	10
Barroso FO	6
Bautista-Salineró M	22
Beedle AEM	2
Berdón PM	167
Berruezo Sánchez A	171
Bertomeu-González V	83, 147, 151, 155
Berve PO	197
Blanco-Velasco M	91
Blas JG	167
Boquete L	107
Braxton A	18
Bueno H	123

C

Cabezas E	127
Calle D	103
Calvillo Arbizu J	119
Camara Rey O	171
Cano del Pozo M	22
Cano J	151
Cano M	55
Cano-Manuel JL	179
Canós MA	87
Cañadas M	189
Carmona Sánchez P	205
Carro J	115
Castelli J	127
Castillo-Rabazo J	187
Castro de la Nuez P	119
Cavaliere C	107
Cepeda Chafía S	51

Chen R	10
Chénier F	111
Chil R	75
Cuba Gato MA	183
Cubero L	127
Cussó L	103

D

De Andrés J	87
de Crevoisier R	127
de Luis García R	51
del Campo F	63
Del Cerro CF	159, 179, 193
Desco M	103, 159, 167, 179, 193
Durá JL	87
Durán-Rey D	187

E

Elola Artano A	197
Esparza-Iaizzo M	42

F

Fácil L	151
Ferreira D	95
Ferrer-Bonsoms JA	30

G

Galán A	167, 179
Galán C	34
Gallego-Ferrer G	26
García A	46
García Carmona R	14
García-Blas J	159, 179, 193
García-Martín E	107
García-Sáez G	123, 131
Garnés Camarena O	201
Giménez RC	159
Gómez C	55, 59, 71
Gómez EJ	67, 79, 205
Gómez M	115
Gómez-Cruz C	189
Gómez-Grande A	79
Gómez-Pilar J	55, 59
Gomis P	95
González-Portillo MR	187
Goya Esteban R	22
Gutiérrez R	107
Gutiérrez -de Pablo V	59, 71
Gutiérrez Martín A	6, 99
Gutiérrez Tobal GC	63
Guzmán-García C	67

H			
Hernando ME	123, 131	Moreno-Castán A	103
Hidalgo Torres LA	75	Muñoz-Barrutia A	18, 189
Hornero R	55, 59, 63, 71, 163	Muñoz-Romero S	91
Hornero Sos F	83, 147, 155	N	
Hruban R	18	Navarro González R	51
Huerta Herraiz A	139	Navarro Ruiz E	38
I		Nicolás-Sáenz L	18
Iniesta JM	131	Núñez P	22
Iriarte A	46	O	
Isasa Reinoso I	10	Oropesa I	67
J		Ortiz M	107
Jauregui Garrido B	171	P	
Jiménez García J	63	Palmieri F	95
K		Pardo Picazo MA	38
Kiemen A	18	Pascau J	127
Klinzing JG	42	Pascual-Valdunciel A	6
L		Pérez Valdivia MA	119
Laguna P	95	Pérez-Benito D	75
Laguna S	189	Pérez-Gandía C	131
Larraga García B	99	Pérez-Velasco S	163
López Dorado A	107	Piol A	193
López-Agudelo I	187	Pizarro-Chong A	111
López-Larraz E	42	Plaza de Miguel C	135
Lopo-Martínez V	6	Plaza-Seco C	91
Losada H	143	Poza J	22, 55, 59, 71
Lovas A	10	Pueyo E	95, 115
M		Q	
Malanda Triguero A	201	Quesada Dorador A	83, 147, 155
Manuel-Cano JL	167	Quintana Díaz M	99, 205
Mares-Bou S	26	R	
Margelí C	46	Ràfols P	34
Martí-Bonmatí L	87	Ramírez J	95
Martín González E	175	Reina Tosina J	119
Martínez JP	95	Revilla-Orodea A	175
Martínez Rodrigo A	139	Revilla-Vallejo M	55
Martínez Seijas V	123	Reyes Leiva KM	183
Martínez-Cagigal V	163	Rico-Gómez I	189
Maturana-Candelas A	71	Rieta Ibáñez JJ	83, 139, 147, 151, 155
Mayans B	46	Roa Romero LM	119
Medina López R	119	Roca-Cusachs Soulere P	2
Méndez de Vigo Iriarte I	14	Rodríguez-Fernández J	26
Minguez J	42	Rodríguez-Galván JR	175
Molas C	46	Rodríguez Rodríguez M	99
Möller K	10	Rodríguez Matesanz M	205
Monasterio V	115	Rojo-Álvarez JL	91
Montesano L	42	Romera M	34
Moreno Muñoz G	123	Rubio Bolívar J	99, 205
		Ruiz JE	95

S

Saiz J	87
Sales Bellés C	171
San Martín L	143
San Martín Retegi A	30
Sánchez Anzules R	135
Sánchez-González P	67, 79, 205
Sánchez-Margallo FM	135, 187
Sánchez-Margallo JA	135, 187
Santamaría-Vázquez E	163
Santos Paz JA	14
Sebastián Aguilar R	171
Seiffert AP	79
Serrancolí G	46
Serrano J	127
Serrano Olmedo JJ	183
Sevilla-Ruiz MT	175
Simon A	127
Solanes C	87
Sosenko K	159
Soto Iglesias D	171
Stashuk DW	201

T

Talaminos Barroso A	119
Tapia-Galisteo J	131
Tejo-Otero A	143
Tola-Arribas MA	22, 55
Torner J	46
Trujillo-Muñoz S	26

U

Urgelés D	131
Urrea JF	179
Urteaga Urizarbarrena J	197

V

Valle Morgado C	203
Vaquerizo Villar F	63
Vaquero JJ	75
Verdú C	205
Villarejo-Galende A	79
Vraka A	83, 147, 155

W

Wik L	197
Wirtz D	18
Wood L	18
Wu P	18

Z

Zangróniz R	151
-------------	-----