

CONGRESO CASERB

LIBRO DE ACTAS

XXXVIII Congreso
Anual de la
Sociedad Española
de Ingeniería Biomédica

ORGANIZADORES Y COLABORADORES:



GRUPO DE INGENIERÍA BIOMÉDICA
UNIVERSIDAD DE VALLADOLID



BioRes
BIOENGINEERING
AND RESUSCITATION

Sociedad Española de
INGENIERÍA BIOMÉDICA





LIBRO DE ACTAS

25 - 27 de noviembre de 2020

XXXVIII Congreso Anual de la Sociedad Española de Ingeniería Biomédica CASEIB 2020

Los contenidos de esta publicación han sido evaluados por el Comité Científico que en ella se relaciona y según el procedimiento que se recoge en www.caseib.es/2020/

Presidente del Comité Organizador:

Roberto Hornero Sánchez

Secretario del Comité Organizador:

Jesús Poza Crespo

Editores:

Roberto Hornero Sánchez

Jesús Poza Crespo

Carlos Gómez Peña

María García Gadañón

Maquetación:

Carlos Gómez Peña

Unai Irusta Zarandona

Verónica Barroso García

Aarón Maturana Candelas

Diseño de portada:

Pablo Núñez Novo

ISBN: 978-84-09-25491-0



Libro de Actas del XXXVIII Congreso Anual de la Sociedad Española de Ingeniería Biomédica

Se distribuye bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional.

Jueves, 26 de noviembre de 2020, a las 10:15

Sesión oral: Señales Biomédicas III

Moderadores: Raimon Jané Campos y Unai Irusta Zarandona

Análisis de flujo aéreo y saturación de oxígeno en sangre mediante transformada wavelet para la detección de la apnea obstructiva del sueño infantil.....	315
Análisis de la variabilidad temporal de la onda P para predecir el resultado de la ablación por catéter en fibrilación auricular paroxística.....	319
Diseño de un prototipo de manga sensorizada para el registro de electromiografía de alta densidad en el antebrazo.....	323
Predicción a Largo Plazo del Resultado de la Ablación Quirúrgica en Fibrilación Auricular Mediante el Uso de una Única Derivación del Electrocardiograma Preoperatorio.....	327
Estudio de la relación entre el gen MAPT y la conectividad cerebral en la demencia por enfermedad de Alzheimer.....	331
Evaluación de la Calidad en Registros Electrocardiográficos Procedentes de Pacientes con Fibrilación Auricular Mediante una Red Neuronal Convolucional.....	335

Sesión oral: Informática Biomédica

Moderadores: Enrique J. Gómez Aguilera y Félix Fanjul Vélez

Modelo de deep learning basado en la arquitectura Inception para el diagnóstico de la apnea del sueño infantil mediante la señal de oximetría.....	340
Caracterización in silico de la duración de la repolarización y su variabilidad en el síndrome de QT Largo Tipo I bajo estimulación beta adrenérgica.....	344
Segmentación automática de instancias aplicada a retinografías para la segmentación del disco óptico y la excavación.....	348
Algoritmo multietapa para la detección de ventilaciones en la impedancia torácica durante la resucitación cardiopulmonar.....	352
Caracterización de la morfología foveal: parametrización, diferencias de sexo y efectos de la edad.....	356
Determinación del efecto de la ablación en tejido porcino mediante un láser Nd:YAG en aplicaciones quirúrgicas.....	360

Informática Biomédica

Jueves, 26 de noviembre de 2020

Modelo de deep learning basado en la arquitectura Inception para el diagnóstico de la apnea del sueño infantil mediante la señal de oximetría

F. Vaquerizo Villar^{1,4}, D. Álvarez González^{2,4}, L. Kheirandish Gozal³, G.C. Gutiérrez Tobal^{1,4}, V. Barroso García^{1,4}, E. Santamaría Vázquez^{1,4}, F. del Campo^{2,4}, D. Gozal³, R. Hornero^{1,4}

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 Department of Child Health, The University of Missouri School of Medicine, Columbia, Missouri, EEUU, gozald@health.missouri.edu

⁴ Centro de Investigación Biomédica en Red en Bioingeniería, Biomateriales y Nanomedicina, (CIBER-BBN), España

Resumen

En este estudio se evalúa la utilidad de una arquitectura deep learning basada en módulos Inception para mejorar la capacidad diagnóstica de la señal de saturación de oxígeno en sangre (SpO₂) en la ayuda al diagnóstico de la apnea obstructiva del sueño (AOS) infantil. Estudios recientes demandan la aplicación de nuevas arquitecturas de deep learning que permitan solventar las limitaciones de los métodos convencionales. En este sentido, los módulos Inception permiten realizar un análisis multiescala, que es capaz de obtener una caracterización más precisa de las señales bajo estudio que otros métodos de deep learning. Nuestra propuesta consiste en la aplicación de una arquitectura Inception a la señal de SpO₂ para estimar el índice de apnea-hipopnea (IAH). El modelo Inception obtenido fue validado en una base de datos compuesta por 1628 registros de SpO₂ de sujetos pediátricos. El IAH estimado por el modelo Inception alcanzó un elevado rendimiento diagnóstico, mostrando un Cohen's kappa de cuatro clases de 0.520, así como precisiones del 79.2%, 95.7% y 97.8% para los umbrales del IAH de 1, 5 y 10 eventos por hora. Además, el nuevo modelo superó la capacidad diagnóstica de dos métodos convencionales: el índice de desaturación de oxígeno del 3% y una red neuronal perceptrón multicapa entrenada en un estudio previo con características de la señal de SpO₂. Estos resultados sugieren que la arquitectura Inception es capaz de obtener nueva información diagnóstica de la señal de oximetría y mejorar la estimación del IAH en el contexto de la AOS infantil.

1. Introducción

La apnea obstructiva del sueño (AOS) pediátrico es un trastorno de alta prevalencia en la población infantil (1%-5%) [1]. La AOS está caracterizada por la recurrencia de episodios de ausencia total (apneas) o parcial (hipopneas) de respiración durante el sueño de los niños, que derivan en un sueño no reparador [1,2]. En caso de no ser tratada, los niños afectados pueden sufrir múltiples consecuencias negativas para su salud y desarrollo, como alteraciones neuroconductuales, cardiovasculares y metabólicas [1,3]. La prueba de diagnóstico estándar es la polisomnografía (PSG) nocturna [1]. Esta prueba requiere que los niños pasen al menos una noche en una unidad especializada del sueño, donde se registran múltiples señales biomédicas mientras duermen [1,3]. Estos registros son analizados por especialistas médicos para anotar las apneas e hipopneas con el objetivo de estimar el índice de apnea-hipopnea

(IAH), que es el parámetro utilizado para diagnosticar la AOS [2]. A pesar de su efectividad, la PSG es una prueba compleja, con un coste elevado, altamente intrusiva para los niños y que presenta disponibilidad limitada, produciéndose así un retardo en el diagnóstico y tratamiento de la AOS en los niños afectados [4].

Debido a estas limitaciones, la comunidad científica se ha centrado en los últimos años en la búsqueda de pruebas diagnósticas más sencillas como alternativa a la PSG [4]. En este sentido, la señal de saturación de oxígeno en sangre (SpO₂) procedente de la oximetría nocturna ha sido frecuentemente utilizada, ya que se trata de una técnica sencilla, fiable y no intrusiva [4]. Estudios previos han obtenido resultados prometedores utilizando enfoques de análisis automático de la señal de SpO₂ basados en la extracción y selección de características (*feature engineering*) [5-7]. Sin embargo, estos enfoques tradicionales tienen dos grandes limitaciones [8]: (i) requieren un gran conocimiento para identificar, *a priori*, qué características deben ser extraídas; y (ii) proporcionan un nivel de abstracción bajo, limitando así su capacidad de detectar patrones complejos en los datos. Estos inconvenientes pueden llevar a omitir información relevante de la señal de SpO₂ relacionada con los eventos de apnea e hipopnea (eventos apneicos).

Las limitaciones anteriores pueden ser minimizadas mediante la aplicación de algoritmos de aprendizaje profundo (*deep learning*), que permiten aprender de manera automática patrones complejos a partir de la señal en crudo mediante el empleo de arquitecturas con múltiples niveles de abstracción [8]. Estos algoritmos han mejorado el rendimiento de los métodos convencionales en áreas como el reconocimiento de imágenes, el procesamiento del lenguaje o el análisis de series temporales. [8]. Además, estudios previos han demostrado la utilidad de los métodos de *deep learning* aplicados a señales fisiológicas procedentes de la PSG para detectar fases del sueño, eventos apneicos y/o estimar el IAH en pacientes adultos de AOS [9]. En el contexto de la AOS infantil, solamente dos estudios preliminares de nuestro grupo de investigación han utilizado técnicas de *deep learning*, concretamente redes neuronales convolucionales (CNNs)

[10,11]. Estos estudios demandaron la necesidad de nuevas arquitecturas de *deep learning* que permitieran corroborar la superioridad de estos algoritmos con respecto a los enfoques tradicionales de *feature engineering*.

En este estudio, se propone el uso de una arquitectura *Inception* de *deep learning*, que, a diferencia de las CNNs, permite aprender características a múltiples escalas temporales de manera simultánea [12]. Trabajos anteriores han mostrado que la señal de SpO₂ contiene información relevante a múltiples escalas [4,7]. Por consiguiente, este estudio parte de la hipótesis de que la arquitectura *Inception* podría ayudar a extraer de manera automática características relevantes de la señal de SpO₂ a diferentes escalas en el contexto de la AOS infantil. El objetivo del estudio es, por tanto, evaluar la utilidad de una arquitectura *Inception* para estimar el IAH a partir de la señal de SpO₂ en niños con sospecha de AOS.

2. Sujetos y señales

En este estudio se ha analizado la base de datos pública *Childhood Adenotonsillectomy Trial* (CHAT), cuyo protocolo se encuentra en el material suplementario de [13]. CHAT está compuesta por 1628 estudios del sueño de niños de 5 a 10 años. Las apneas e hipopneas de cada sujeto fueron marcadas según las reglas de la Academia Americana de Medicina del Sueño [2]. El IAH, calculado como el número de apneas e hipopneas por hora de sueño, fue utilizado para diagnosticar la severidad de la AOS [2]. En este estudio, se han empleado los puntos de corte habituales de 1, 5 y 10 eventos por hora (e/h) del IAH para determinar los grupos de severidad no-AOS (IAH < 1 e/h), AOS leve (1 ≤ IAH < 5 e/h), AOS moderado (5 ≤ IAH < 10 e/h) y AOS severo (IAH ≥ 10 e/h) [5-7].

Los registros de SpO₂ fueron adquiridos durante la PSG utilizando frecuencias de muestreo de 1 a 512 Hz, que posteriormente se remuestrearon a una frecuencia común de 1 Hz. Para cada sujeto, se dividieron las señales de SpO₂ en segmentos de 20 minutos (1200 muestras), que permiten detectar clusters de desaturaciones, cuya duración mínima es de diez minutos. Para cada segmento, se estimó el IAH parcial con las anotaciones de eventos apneicos proporcionadas por los especialistas [11]. La población bajo estudio se dividió en tres grupos: grupo de entrenamiento, utilizado para entrenar la arquitectura *Inception*; validación, empleado para la optimización de hiperparámetros; y test, utilizado para evaluar el

rendimiento diagnóstico de la metodología. El conjunto de entrenamiento se compuso de 859 registros (25587 segmentos) de SpO₂ de los grupos *baseline* (453) y *follow-up* (406) de CHAT, mientras que el tercer grupo, *nonrandomized*, se dividió en grupo de validación (primeros 500 sujetos: 14372 segmentos) y grupo de test (últimos 279 sujetos: 8132 segmentos). La tabla 1 muestra las características clínicas y sociodemográficas de la población bajo estudio.

3. Metodología

3.1. Arquitectura *Inception*

La arquitectura propuesta está inspirada en el trabajo de Szegedy *et al.* [12] para la clasificación de imágenes. Esta arquitectura incorpora módulos *Inception* que procesan los datos de entrada mediante varios caminos en paralelo, cada uno de ellos compuesto de capas convolucionales con distinto tamaño de filtro, concatenando sus salidas [12]. Esto permite aprender características a distintas escalas en el mismo nivel de abstracción, lo que ha llevado a mejorar arquitecturas tradicionales de *deep learning* en clasificación de imágenes [12]. La figura 1 muestra la arquitectura *Inception* empleada en este estudio.

La sección de entrada de la red son los segmentos de 20 minutos de la señal de SpO₂. A continuación, la arquitectura propuesta procesa la entrada mediante λ_l módulos *Inception*. Cada módulo *Inception* consta de cuatro bloques convolucionales (*conv blocks*) en paralelo, cada uno de ellos compuesto por: (i) una convolución 1D (*conv*), que extrae los mapas de características (*feature maps*) [8]; (ii) *batch normalization* (BN), que normaliza los *feature maps* [8]; (iii) *rectified linear unit* (ReLU), que aplica una función de activación para introducir no-

	Todos	Entrenamiento	Validación	Test
Sujetos (n)	1628	859	500	279
Edad (años)	7[6-8]	7[6-8]	7[6-8]	7[6-8]
Varones (n)	777 (47.7%)	417 (48.5%)	225 (46.2%)	135 (49.8%)
IMC (kg/m ²)	17.2 [15.4-21.5]	17.3 [15.5-22.3]	17.1 [15.8-20.7]	17.5 [15.6-20.5]
IAH (e/h)	1.6 [0.6-4.7]	3.1 [1.4-6.9]	0.8 [0.4-1.5]	0.8 [0.4-1.7]

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

Tabla 1. Características sociodemográficas y clínicas de la población bajo estudio

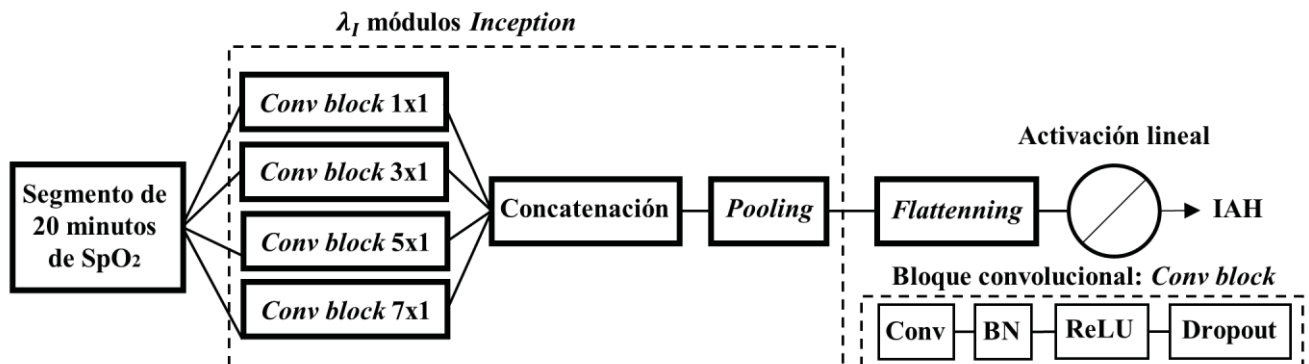


Figura 1. Descripción de la arquitectura *Inception* propuesta.

linealidad [8]; y (iv) *dropout*, que elimina conexiones entre elementos de la red durante el entrenamiento con probabilidad p_{drop} para minimizar el *overfitting* [8]. La diferencia entre los distintos *conv blocks* de cada módulo *Inception* es el tamaño de los filtros de la convolución 1D de cada bloque: 1x1, 3x1, 5x1 y 7x1. La salida de los distintos *conv blocks* de cada módulo *Inception* es concatenada [12], seguida de una capa de *max-pooling* con un factor $K=3$ que reduce la dimensionalidad [8]. Después de los λ_l módulos *Inception*, una capa de *flattening* transforma los 2-D *feature maps* en datos 1-D [8]. Finalmente, una unidad de activación lineal es utilizada para obtener el IAH estimado para cada segmento de SpO₂ a la entrada. Para cada sujeto, se obtuvo el IAH como el valor promedio del IAH estimado para cada segmento de 20 minutos de la señal de SpO₂ correspondiente.

La implementación de la arquitectura *Inception* se llevó a cabo en la librería *Keras*. Los pesos de la red se inicializaron con el método He-normal, empleando el algoritmo de Adam con una tasa de aprendizaje inicial de 0.001 para actualizar los pesos en cada iteración [9]. Como función de error se utilizó la *Huber loss*, ya que tiene un hiperparámetro, delta (δ), que se puede ajustar para controlar la importancia de los *outliers*.

3.2. Comparación con métodos convencionales

Los siguientes métodos convencionales también han sido aplicados para comparar el rendimiento diagnóstico de la arquitectura *Inception*:

- Enfoque clínico: índice de desaturación de oxígeno del 3% (ODI3). ODI3 fue calculado como el número de desaturaciones de al menos el 3% por hora para cada señal de SpO₂. Este parámetro se suele utilizar en el contexto clínico de la AOS, así como con fines comparativos [4].

- Enfoque de *feature engineering* clásico: red neuronal perceptrón multicapa (MLP), entrenada por Hornero *et al* [5] para estimar el IAH con características extraídas de la señal de SpO₂. El modelo MLP diseñado por Hornero *et al* fue validado en una base de 4191 sujetos pediátricos [5], la mayor en la literatura. En el presente estudio, el modelo MLP ha sido aplicado a nuestro conjunto de test.

3.3. Análisis estadístico

El rendimiento diagnóstico del IAH estimado por la arquitectura *Inception* fue evaluado por medio de la matriz de confusión (de 4 clases), la precisión global (suma de la diagonal principal), *Cohen's kappa* (κ), sensibilidad (S), especificidad (E) y precisión (P).

4. Resultados

4.1. Optimización de la arquitectura *Inception*

Los hiperparámetros de la arquitectura a optimizar fueron el número de módulos *Inception* (λ_l), la probabilidad de dropout (p_{drop}) y el parámetro delta de la *Huber loss* (δ). El conjunto de entrenamiento se utilizó para entrenar distintos modelos *Inception* variando estos parámetros, mientras que en el conjunto de validación se obtuvo el valor de kappa para cada uno de estos modelos. La combinación óptima de hiperparámetros que alcanzó un mayor kappa en validación fue: $\lambda_l=5$, $p_{drop}=0.1$ y $\delta=8$.

4.2. Rendimiento diagnóstico del modelo *Inception*

La figura 2 muestra la matriz de confusión del modelo *Inception*, el ODI3 y la red MLP en el conjunto de test. El modelo *Inception* clasificó correctamente al 73.7% (205/279) de los sujetos según su severidad de la AOS, superando al ODI3 (64.2%, 179/279) y a la red MLP (63.8%, 178/279). En la tabla 2 se pueden ver las métricas de rendimiento diagnóstico de los tres métodos para los




Figura 2. Matriz de confusión de la red *Inception*, el ODI3, y la red MLP en el conjunto de test. 1: no-AOS (IAH < 1 e/h); 2: AOS leve (1 ≤ IAH < 5 e/h); 3: AOS moderado (5 ≤ IAH < 10 e/h); 4: AOS severo (IAH ≥ 10 e/h)

IAH estimado	Inception			ODI3			MLP		
	IAH = 1 e/h	IAH = 5 e/h	IAH = 10 e/h	IAH = 1 e/h	IAH = 5 e/h	IAH = 10 e/h	IAH = 1 e/h	IAH = 5 e/h	IAH = 10 e/h
S (%)	70.8	72.1	80.8	77.9	69.8	65.4	83.2	76.7	92.3
E (%)	84.9	100	99.6	68.1	99.6	100	59.0	98.7	99.2
P (%)	79.2	95.7	97.8	72.0	95.0	96.8	68.8	95.3	98.6
kappa	0.520			0.401			0.422		

Tabla 2. Rendimiento diagnóstico de la red *Inception*, el ODI3, y la red MLP en el conjunto de test para los puntos de corte de 1, 5 y 10 e/h.

puntos de corte del IAH de 1, 5 y 10 e/h. Nuestra propuesta alcanzó un kappa de 0.520, superior al del ODI3 (0.401) y la red MLP (0.422). Además, el modelo *Inception* superó al ODI3 y a la red MLP en la mayoría de las métricas de rendimiento para los tres puntos de corte del IAH, presentando una carga computacional similar en el conjunto de test.

5. Discusión y conclusiones

En este trabajo se ha evaluado la utilidad de una arquitectura novedosa de *deep learning* compuesta por módulos *inception* para mejorar la capacidad diagnóstica de la señal de SpO₂ en el contexto de la AOS infantil. El modelo propuesto alcanzó un elevado rendimiento diagnóstico para predecir la severidad de la AOS en niños, mejorando al ODI3 y a la red MLP diseñada en un relevante estudio previo [5]. En las matrices de confusión de la figura 2, se observa cómo nuestro modelo *Inception* supera de forma más notable al ODI3 y a la red MLP en la detección del grupo 1 (no-AOS). Por tanto, nuestra propuesta ayudaría a la reducción de las listas de esperas y los costes médicos asociados al diagnóstico, ya que en niños con un IAH < 1 e/h sólo se recomienda realizar la PSG si persisten los síntomas de la AOS [3].

En los últimos años, varios estudios se han centrado en el uso de la señal de SpO₂ como ayuda al diagnóstico de la AOS infantil [4]. Estudios recientes han evaluado el rendimiento diagnóstico de metodologías de *feature engineering* para estimar el IAH en sujetos pediátricos [5-7]. Estos estudios alcanzaron precisiones en un rango de 75.2%-82.7%, 79.4%-81.9% y 88.2%-91.1% para los puntos de corte de 1, 5 y 10 e/h, respectivamente [5-7]. Sin embargo, solamente un estudio previo desarrollado por nuestro grupo aplicó una red CNN, la técnica más común de *deep learning*, a la señal de SpO₂ para estimar el IAH en la misma base de datos que el presente trabajo [11]. Este estudio alcanzó un kappa de 0.31 y precisiones del 74.8%, 90.7% y 95.1% para los puntos de corte de 1, 5 y 10 e/h [11], métricas que han sido superadas por la nueva arquitectura *Inception* propuesta.

Este estudio presenta algunas limitaciones. En primer lugar, el número de sujetos del grupo no-AOS es elevado en comparación con los demás grupos de severidad, especialmente los grupos AOS moderado y AOS severo. En este sentido, la validación de nuestra propuesta en otras bases de datos aumentaría la generalización de los resultados. Otra limitación es que el entrenamiento de la arquitectura *Inception* se ha realizado desde cero, al no existir arquitecturas de *deep learning* preentrenadas para señales 1D. Finalmente, la composición de los módulos *Inception* fue escogida siguiendo las recomendaciones de Szegedy *et al* [12]. Por consiguiente, se requieren pruebas adicionales para encontrar la configuración óptima de estos módulos para nuestro problema particular (señal de oximetría y detección de AOS).

En resumen, una arquitectura de *deep-learning* compuesta por módulos *Inception* ha demostrado ser útil para aprender de manera automática características de la señal de oximetría asociadas a los eventos apneicos en múltiples escalas temporales. Además, la arquitectura propuesta

alcanzó un elevado rendimiento diagnóstico, superando al ODI3 y la red MLP, así como a los resultados obtenidos en estudios previos. Estos resultados sugieren que los módulos *Inception* pueden ser utilizados para mejorar la capacidad diagnóstica de la señal de oximetría en el contexto de la AOS infantil.

Agradecimientos

Este estudio ha sido financiado por el Ministerio de Ciencia Innovación y Universidades-Agencia Estatal de Investigación y FEDER (DPI2017-84280-R y RTC-2017-6516-1), por el CIBER-BBN (ISCII), por la Sociedad Española de Neumología y Cirugía Torácica (SEPAR 1649/218) y por la Sociedad Española de Sueño (Beca de Investigación SES 2019). F. Vaquerizo Villar cuenta una ayuda para la Formación de Profesorado Universitario del Ministerio de Educación, Cultura y Deporte (FPU16/02938). V. Barroso y E. Santamaría cuentan con una ayuda concedida por la Consejería de Educación de la Junta de Castilla y León y el Fondo Social Europeo.

Referencias

- [1] C. L. Marcus *et al.*, “Diagnosis and Management of Childhood Obstructive Sleep Apnea Syndrome,” *Pediatrics*, vol. 130, no. 3, pp. e714–e755, 2012.
- [2] C. Iber *et al.*, “The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specification,” *J. Clin. Sleep Med.*, vol. 3, no. 7, p. 752, 2007.
- [3] M. L. Alonso-Álvarez *et al.*, “Documento de consenso del síndrome de apneas-hipopneas durante el sueño en niños,” *Arch Bronconeumol*, vol. 47, no. Supl 5, pp. 2–18, 2011.
- [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] R. Hornero *et al.*, “Nocturnal Oximetry-based Evaluation of Habitually Snoring Children,” *Am. J. Respir. Crit. Care Med.*, vol. 196, no. 12, pp. 1591–1598, 2017.
- [6] Z. Xu *et al.*, “Cloud algorithm-driven oximetry-based diagnosis of obstructive sleep apnoea in symptomatic habitually snoring children,” *Eur. Respir. J.*, vol. 53, no. 2, 2019.
- [7] F. Vaquerizo-Villar *et al.*, “Detrended fluctuation analysis of the oximetry signal to assist in paediatric sleep apnoea-hypopnoea syndrome diagnosis,” *Physiol. Meas.*, vol. 39, no. 11, p. 114006, 2018.
- [8] I. Goodfellow *et al.*, *Deep Learning*. MIT Press, 2016.
- [9] S. S. Mostafa *et al.*, “A systematic review of detecting sleep apnea using deep learning,” *Sensors (Switzerland)*, vol. 19, no. 22, pp. 1–26, 2019.
- [10] 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.
- [11] F. Vaquerizo-Villar *et al.*, “Automatic Assessment of Pediatric Sleep Apnea Severity Using Overnight Oximetry and Convolutional Neural Networks,” in *42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2020, pp. 633–636.
- [12] C. Szegedy *et al.*, “Going Deeper with Convolutions,” *arxiv*, 2015. [Online]. Available: <https://arxiv.org/abs/1409.4842v1>.
- [13] C. L. Marcus *et al.*, “A Randomized Trial of Adenotonsillectomy for Childhood Sleep Apnea,” *N. Engl. J. Med.*, vol. 368, no. 25, pp. 2366–2376, 2013.

ÍNDICE DE AUTORES

A

Abella, M.	73, 85, 206, 273, 285, 439, 447, 459
Acha, B.	468
Aguado, H. J.	397
Aguiló, J.	256
Albaladejo-Belmonte, M.	240
Alberola-Rubio, J.	240
Albert-Smet, I.	265
Alcaraz Martínez, R.	2, 14, 105, 109, 117, 319, 327, 335, 409, 422, 430, 476
Aldazabal, J.	40, 389
Alegre, M.	57, 235
Aleixandre Soriano, I.	77
Alfárez, S.	157
Alonso González, E.	480
Alonso López, J. F.	323
Álvarez González, D.	252, 315, 340
Álvarez Rodríguez, J.	145, 464
Álvarez Rodríguez, M.	190
Amado Forero, L.	65
Aragón Arqués, J.	310
Aramendi Ecenarro, E.	352, 418, 426, 480
Arce-Diego, J. L.	294, 360, 376
Arias Palomares, M. A.	319, 335, 476
Armada-Maresca, F.	36
Artieda, J.	57, 235
Artola, G.	40
Astrain, J. J.	235
Ayala Fernández, U.	356
Aymerich Moreno, C.	165
Aznar-Cervantes, S. D.	36

B

Bachiller, A.	248
Bailón, R.	256
Balaban, E.	61
Bardají Ortiz, S.	414
Barea, R.	472
Barquero-Pérez, O.	177
Barrachina Fernández, M.	97
Barrenechea Carrasco, M.	356
Barrera, K.	157
Barros, R.	468
Barroso García, V.	252, 340
Bayés-de-Luna, A.	10
Belletti, R.	141

Berdón, P. M.	285
Bernal Ruíz, M. L.	256
Berrocoso, E.	455
Bertomeu González, V.	105, 109, 422, 430
Besné, G. M.	57, 235
Bikuña Izaguirre, M.	389
Bizy, A.	298
Boquete, L.	472
Borràs Argemí, M.	269
Bosch Roig, I.	77
Bote, J.	53
Botija Yagüe, M. P.	214
Brox, P.	85
Buj-Corral, I.	48
Bujanda Cundin, X.	185
Buruaga Lamarain, L.	173

C

Caffarena Fernández, G.	93
Calero Núñez, S.	14, 117
Callejón, M. A.	198
Calvillo Arbizu, J.	227
Calvo, C. J.	298
Calvo-Haro, J.	365
Camacho Ramos, E.	77
Cano, M.	121, 260
Cano, O.	101
Cano Serrano, J.	2
Canós, M. A.	306
Carnero González, E.	389
Carretero, J.	85
Carvajal Ahumada, L. A.	19
Castells, F.	393
Castrejón, S.	393
Cavaliere, C.	472
Cenis, J. L.	36
Cepero Escribano, V.	27
Ceruelo Abajo, S.	190
Cervigón, R.	393
Chamorro Servent, J.	269
Cherry, E.	141
Chil, R.	81, 281, 401
Cichy, J.	36
Cirillo, G.	36
Cirugeda Roldán, E. M.	14, 117
Cobo, A.	89
Colly, A.	48

Colomer, A.	443	Fernández Santos, M. E.	161
Corbett, B.	53	Ferreira, D.	434
Corral Bolaños, M.	181	Finotti, E.	109, 422
Corral, J.	181	Francés Morcillo, L.	201
Courtial, E. J.	48	Franco-Rosado, P.	198
Cubero Gutiérrez, L.	61		
Cygankiewicz, I.	10	G	
D		Gabilondo Cuellar, I.	356
Daya, M. R.	480	Galán González, A.	273, 459
De Andrés, J.	290, 306	Gallardo Madueño, G.	181
de la Cámara, C.	256	Gallego-Ferrer, G.	153
de la Nava, A. S.	161	Ganoza-Quintana, J. L.	294
de los Reyes Guzmán, A.	190	García Blas, J.	85, 206, 273, 459
del Campo, F.	252, 315, 340	García-Briega, M. I.	153
Del Cerro, C. F.	73, 206, 285, 439, 447	García Carmona, R.	169
del Valle Hidalgo, A.	273, 459	García-Carretero, R.	177
Descó, M.	73, 85, 206, 273, 285, 439, 447, 459	García-Casado, J.	240
Díaz Carnicero, J.	214	García-Cazorla, M. A.	248
Díaz Gómez, D.	65	García-Duarte Sáenz, L.	384
Díaz-Pernas, F. J.	397	García, E.	256
Díaz Zelaia, A.	173	García Gadañón, M.	315, 484
Dómine Gómez, M.	181	García-Martin, E.	472
Durá, J. L.	290, 306	García Martínez, C. A.	93, 414
Durán Rey, D.	129	García-Mato, D.	384
E		García Teruel, M.	327
Eguizabal Argaiz, C.	173	Gil Agudo, A.	190
Elola Artano, A.	426	Gil-Bazo, I.	181
Enero Navajo, J.	14	Gil, E.	256
Enríquez Medina, R.	169	Giménez, R. C.	285, 447
Escobar, F.	137	Gimeno Tébar, M.	125
Escribano Cano, P.	327, 476	Gómez Blanco, J. C.	44, 149, 373
Escudero Arnanz, O.	464	Gómez, C.	121, 260, 331, 405
Espinosa-Salinas, I.	223	Gómez Cid, L.	161
Extramiana Esquisabel, L.	389	Gómez-Cruz, C.	265
F		Gómez, E. J.	210, 223, 231, 277, 380, 451
Falcone, F.	235	Gómez-Grande, A.	277, 451
Fanjul-Vélez, F.	294, 360, 376	Gómez-Pilar, J.	405
Farina, B.	181	Gómez-Ribelles, J. L.	153
Farré Ventura, R.	165	Gomis, P.	434
Fenollosa-Artés, F.	48	Gomis-Tena, J.	137
Fenton, F. H.	141	González-Alonso, J.	397
Fernández Avilés, F.	161	González de Julián, S.	214
Fernandez-Bes, J.	344	González-González, A.	373
Fernández Cerezo, M.	89	Gonzalez-Nieto, D.	36
		Gozal, D.	252, 315, 340
		Grigorian Shamagian, L.	161
		Guedan-Duran, A.	36

Guillot-Ferriols, M.	153	Lara-Doña, A.	218, 455
Guinea, G.	36	Largo-Aramburu, C.	36
Gutiérrez-de Pablo, V.	121, 260, 331, 405	Larraga García, B.	369
Gutiérrez Martín, A.	369	Lazaro, J.	256
Gutiérrez, R.	472	Lazo, M.	468
Gutiérrez Tobal, G. C.	252, 315, 340	Ledesma-Carbayo, M. J.	181
Guzmán-García, C.	210	León-Jiménez, A.	218
H			
Haro, J. M.	256	Lombardi, D.	344
Hernando, M. E.	133, 223	López Dolado, E.	190
Hidalgo Olivares, V. M.	117	López Dorado, A.	472
Hidalgo-Torres, L. A.	61, 281, 401	López Gálvez, M. I.	484
Holgado-Cuadrado, R.	177	Lopez-Martin, A.	235
Hornero, R.	121, 244, 252, 260, 315, 331, 340, 405, 484	López Plaza, B.	223
Hornero Sos, F.	105, 109, 327, 422, 430	Lozano Berrio, V.	190
Huerta Herraiz, A.	335, 409	Lozano-Picazo, P.	36
I			
Idris, A.	352, 426	M	
Iniesta-Chamorro, J. M.	223	Macias, P.	401
Invernon Garrido, D.	323	Malanda Trigueros, A.	113
Irigoien, E.	235	Mañana, M. A.	248
Irusta Zarandona, U.	352, 418, 426, 480	Mancha Sánchez, E.	44
J			
Jaén-Vargas, M.	89, 194	Marcos Romero, A. C.	44
Jaureguibeitia Lara, X.	352, 418	Marín, A.	380
Jemni-Damer, N.	36	Marquette, C. A.	48
Jiménez García, J.	315	Martí-Bonmatí, L.	306
Jimenez-Hernando, M.	231	Martín Montero, A.	315
Jiménez, S.	81	Martín Odriozola, A.	201
Jiménez-Torres, C.	210	Martín-Rodríguez, J. F.	198
Jurado-Barba, R.	133	Martín-Yebra, A.	434
K			
Kheirandish Gozal, L.	252, 315, 340	Martínez Agüero, S.	464
Kobler, R. J.	244	Martínez-Albero, E.	277
Kontaxis, S.	256	Martínez, C.	73, 439
Kovalyk, O.	348	Martínez-Cagigal, V.	244
L			
Laguna, P.	6, 256, 344, 434	Martínez Iniesta, M.	327
Laguna, S.	265	Martínez, J. P.	6, 10, 434
Lanceros-Méndez, S.	153	Martínez, Marta	256
Langley, P.	335, 476	Martínez, Marcel	393
		Martínez-Maldonado, A.	133
		Martinez Mateu, L.	141
		Martínez Rodrigo, A.	335, 409
		Martínez-Zarzuela, M.	397
		Matamoros Pacheco, M.	44
		Maturana-Candelas, A.	331, 405
		Mediavilla-Santos, L.	365
		Medina López, R. A.	31
		Mejía Blanco, R. H.	369
		Merino, A.	157

Roa, L. M.	31, 198	Sellés Navarro, I.	348
Rodellar, J.	157	Sereno Moyano, M.	223
Ródenas García, J.	327, 476	Serra, P.	149
Rodrigo, M. J.	472	Serrano, A.	468
Rodríguez, A.	373	Serrano Arriezu, L.	235
Rodríguez Aierbe, C.	173	Serrano, C.	468
Rodríguez Almeida, A. J.	298	Serrano Olmedo, J.	19, 89, 194
Rodríguez-de-Pablo, C.	201	Siddi, S.	256
Rodríguez-González, V.	121	Soguero Ruiz, C.	145, 464
Rodríguez Lázaro, M.	165	Solanes, C.	290, 306
Rodríguez, M.	380	Sorbet Santiago, S.	214
Rodríguez-Rey, J. C.	376		
Rojo, F.	36	T	
Román Martínez, I.	227	Talavera Díaz, F.	190
Romero-Bascones, D.	356	Tapia-Galisteo, J.	133
Romero, L.	137, 141	Tarancón-Rey, J.	145
Romero-Oraá, R.	484	Tarazona, M.	240
Romero, S.	248	Tejedor Nogueras, J.	414
Roycroft, B.	53	Tejo-Otero, A.	48
Rubio Bolívar, J.	369	Tola-Arribas, M. A.	121, 260
Ruipérez-Campillo, S.	393	Toledo, T.	468
Ruiz-Gómez, S. J.	331	Torrado, O.	149
Ruiz, J. E.	434	Torres-Sánchez, S.	455
Ruiz Moreno, A.	319	Tost, A.	248
Ruiz-Solís, S.	277	Tovar, F. A.	73
		Trigo, J. D.	235
S		U	
Saiz, J.	137, 141, 290, 306	Urteaga Urizarbarrena, J.	426
Saiz Vivó, M.	443	Usó Talamantes, R.	214
Sakaltras, N.	73	Usón, J.	373
Salgueria Lazo, M.	31		
Sampedro-Puente, D. A.	344	V	
Sánchez Ávila, C.	97	Valencia, M.	57, 235, 310
Sánchez García, J.	77	Valenzuela López, L.	97
Sánchez-González, P.	210, 231, 277, 380, 451	Vallejo-Illarramendi, A.	23
Sánchez Lara, S.	194	Vaquerizo Villar, F.	252, 340
Sánchez Margallo, F. M.	44, 129, 149, 373	Vaquero, J. J.	61, 81, 265, 281, 401
Sánchez Margallo, J. A.	129	Vásquez López, J.	302
Sánchez-Morillo, D.	218, 455	Vaz Pato, I.	69
Sánchez-Trancón, A.	149	Vega Beltrán, J.	65
Sandberg, F.	101	Verdú Monedero, R.	348
Santamaría-Bustamante, L.	360	Vesga-Castro, C.	23
Santamaría Vázquez, E.	340	Viik, J.	6
Santos Cabrera, S.	173	Vilades, E.	472
Santos Paz, J. A.	169	Villarejo-Galende, A.	451
Seiffert, A. P.	277, 451	Virtuoso, A.	36
Seijo, L. M.	181		