

Jornadas de Automática

Detección automática multicanal de husos de sueño en epilepsia focal

Cristina Montserrat-Font^{a,b,*}, Paula Romano-Romeo^a, Jan Pinyol-Pont^a, Mónica Vicente-Rasoamalala^d,
Miguel A. Mañanas^{a,b,c}, Sergio Romero^{a,b,c}

^a Automatic Control Department (ESAT) and Institute for Research and Innovation in Health (IRIS),
Universitat Politècnica de Catalunya - BarcelonaTech (UPC), Barcelona, España.

^b Institute of Research Sant Joan de Déu, Barcelona, España.

^c CIBER of Bioengineering, Biomaterials and Nanomedicine (CIBER-BBN), Madrid, España.

^d Hospital Universitario Vall d'Hebron, Vall d'Hebron Institut de Recerca (VHIR), Barcelona, España.

To cite this article: Montserrat-Font, C., Romano-Romeo, P., Pinyol-Pont, J., Vicente-Rasoamalala, M., Mañanas, M., Romero, S., 2026. Multichannel automatic detection of sleep spindles in focal epilepsy. *Jornadas de Automática*, 47. <https://doi.org/10.17979/ja-cea.2026.47.13845>

Resumen

Los husos de sueño han emergido como biomarcadores neurofisiológicos en epilepsia focal pediátrica, aunque su identificación manual en registros electroencefalográficos (EEG) continúa siendo un proceso lento y subjetivo. En este trabajo preliminar se presenta una adaptación y optimización multicanal de un método monocanal para la detección automática de husos en pacientes pediátricos con epilepsia focal. El estudio se realizó sobre registros polisomnográficos de siete pacientes, utilizando seis derivaciones bipolares EEG y una validación multicanal basada en detección simultánea de eventos en distintas regiones cerebrales. Los parámetros del detector fueron optimizados mediante la maximización del F1-score respecto a anotaciones de una experta en neurofisiología. La configuración óptima del sistema alcanzó un F1-score global de 0.625, comparable al acuerdo inter-experto descrito en la literatura. Además, las densidades de husos estimadas mostraron rangos fisiológicamente plausibles y coherentes con estudios previos pediátricos. Los resultados sugieren que la detección automática multicanal constituye una herramienta prometedora para el análisis objetivo y reproducible de husos en epilepsia pediátrica.

Palabras clave: Procesamiento y adquisición de señales biomédicas, Ensayo clínico, Validación clínica, Sistemas de apoyo a la decisión y control en medicina, Modelado de neuro-sistemas, Modelado, identificación y simulación de sistemas biomédicos.

Multichannel automatic detection of sleep spindles in focal epilepsy

Abstract

Sleep spindles have emerged as neurophysiological biomarkers in paediatric focal epilepsy, although their manual identification in electroencephalographic (EEG) recordings remains a slow and subjective process. This preliminary study presents a multichannel adaptation and optimization of a single-channel method for the automatic detection of sleep spindles in paediatric patients with focal epilepsy. The study was conducted on polysomnographic recordings from seven patients, using six bipolar EEG derivations and a multichannel validation based on the simultaneous detection of events across different brain regions. Detector parameters were optimized by maximizing the F1-score with respect to annotations from an expert in neurophysiology. The optimal system configuration achieved a global F1-score of 0.625, comparable to inter-expert agreement reported in the literature. In addition, the estimated spindle densities showed physiologically plausible ranges consistent with previous paediatric studies. Overall, the results suggest that multichannel automatic detection constitutes a promising tool for the objective and reproducible analysis of sleep spindles in paediatric epilepsy.

Keywords: Biomedical signal measurement and processing, Clinical trial, clinical validation, Decision support and control in medicine, Neuro-system modeling, Biomedical system modeling, identification, and simulation.

1. Introducción

La epilepsia es una de las enfermedades neurológicas más frecuentes a nivel mundial, afectando a más de 50 millones de personas (OMS, 2025). Se caracteriza por la aparición de actividad neuronal anómala e hipersincrónica que genera una predisposición persistente a presentar crisis epilépticas (Fisher et al., 2014).

En el ámbito de la neurología pediátrica, las epilepsias focales constituyen un grupo especialmente heterogéneo. En estas epilepsias, las crisis se originan en redes neuronales limitadas a un único hemisferio cerebral, aunque su evolución clínica puede variar considerablemente. Mientras algunas formas presentan un curso autolimitado a la infancia y un pronóstico favorable, otras se asocian a alteraciones cognitivas conductuales o del lenguaje con impacto significativo en el neurodesarrollo (Wirrell et al., 2022) (Fortini et al., 2021). Esta variabilidad clínica ha impulsado la búsqueda de biomarcadores capaces de aportar información objetiva sobre la evolución de la enfermedad y facilitar una mejor estratificación de los pacientes (Gallotto et al., 2023).

Los husos de sueño (*sleep spindles*) han emergido en los últimos años como un biomarcador prometedor en este contexto (McLaren et al., 2023). Se definen como ráfagas transitorias de actividad rítmica, típicamente entre 11 y 16 Hz, que aparecen principalmente durante la fase N2 del sueño no REM (Purcell et al., 2017) (Schöner et al., 2018). Estos eventos desempeñan un papel relevante en procesos neurofisiológicos fundamentales, como la plasticidad sináptica, la consolidación de la memoria y el desarrollo cognitivo. En pacientes con epilepsia focal, diferentes estudios han descrito alteraciones tanto en la densidad como en la morfología de estos husos, sugiriendo que estos cambios podrían reflejar un grado de disfunción talamocortical y estar relacionados con alteraciones cognitivas y del lenguaje (Kramer et al., 2021) (Zhang et al., 2023).

Sin embargo, la identificación de estos eventos en registros electroencefalográficos (EEG) de larga duración continúa siendo un proceso complejo, tedioso y altamente dependiente de la experiencia clínica (Parekh et al., 2015). La detección visual de husos de sueño requiere una revisión manual exhaustiva y presenta una elevada variabilidad tanto inter- como intra-experto. De hecho, estudios recientes reportan niveles medios de acuerdo inter-experto (F1-score) de apenas el 0.61, lo que pone de manifiesto la dificultad inherente a la anotación de estos eventos incluso entre especialistas experimentados (Wendt et al., 2024) (Tamamoto et al., 2024). Aunque en los últimos años se han desarrollado diferentes métodos automáticos de detección, la mayoría han sido diseñados utilizando registros monocanales de adultos sanos. Esto limita su aplicación en población pediátrica con patologías neurológicas, donde la morfología de los husos y la dinámica del sueño pueden diferir significativamente. Además, los enfoques basados en un único canal son especialmente vulnerables al ruido localizado y a artefactos, y no permiten capturar adecuadamente la distribución espacial característica de los husos del sueño (Mei et al., 2017).

En este contexto, el objetivo de este trabajo piloto es desarrollar una estrategia automática de detección de husos de sueño basada en una adaptación multicanal de un método monocanal descrito en la literatura, y evaluar su rendimiento frente al criterio clínico de una especialista en neurofisiología del sueño.

2. Metodología

2.1. Base de datos

Este estudio piloto se llevó a cabo utilizando una base de datos de registros polisomnográficos (PSG) de pacientes pediátricos con diagnóstico inicial de epilepsia focal. Los datos fueron adquiridos en la Unidad de Neurología del Hospital Universitario Infantil Vall d'Hebron, y proporcionados tras un proceso previo de anonimización.

La muestra analizada está compuesta por registros de PSG correspondientes a siete sujetos. Los registros de PSG fueron almacenados en formato EDF. Cada registro incluye un total de 104 canales: 30 canales de electroencefalografía (EEG), 2 canales de electrooculografía (EOG), 29 canales de electromiografía (EMG), 5 canales de electrocardiografía (ECG), 18 canales para la monitorización de la actividad respiratoria, 19 canales adicionales correspondientes a variables auxiliares y un canal destinado a las anotaciones clínicas.

Las señales EEG fueron adquiridas con el sistema internacional 10–20, referenciados al mastoide del hemisferio contrario, a una frecuencia de muestreo de 512 Hz. Para este análisis preliminar, una neurofisióloga experta en sueño realizó la clasificación visual de las fases del sueño, a partir de la cual se seleccionaron aproximadamente 20 minutos de fase N2 de cada registro.

2.2. Detección manual de husos de sueño

La detección y anotación manual de los husos fue realizada por una neurofisióloga experta en sueño, siguiendo los criterios establecidos por la *American Academy of Sleep Medicine* (AASM) (Iber et al. 2015). Para la visualización de las señales se empleó un montaje bipolar longitudinal tipo doble banana (ver Figura 1), junto con un filtrado paso-banda entre 0.5 y 30 Hz, con el objetivo de facilitar la identificación visual de estos transitorios.




Figura 1: Montaje EEG tipo “doble banana” con los electrodos seleccionados, agrupados por regiones: hemisferio izquierdo (lila), línea media (amarillo) y hemisferio derecho (azul). Figura adaptada de: (Shlobin et al., 2021)

Las anotaciones realizadas por la experta siguieron un criterio multicanal, es decir, se generó una única marca temporal para cada huso independientemente del canal en el que apareciera. Además, se incorporaron criterios clínicos adicionales específicos del estudio: se consideró válido un huso de sueño únicamente cuando presentaba una distribución bilateral o, al menos, cuando aparecía simultáneamente en uno de los hemisferios cerebrales y en la línea media (Fz-Cz o Cz-Pz).

2.3. Detección automática de husos de sueño

Las señales EEG fueron re-referenciadas de forma offline al mismo montaje bipolar doble-banana utilizado por la experta durante la anotación manual, obteniendo un total de 6 derivaciones bipolares (F3-C3, C3-P3, Fz-Cz, Cz-Pz, F4-C4 y C4-P4). Sobre estos canales, se aplicó un filtro Butterworth de cuarto orden entre 0.5 y 30 Hz.

Una vez completado el preprocesado, la detección automática multicanal de husos de sueño se basó en el algoritmo DETOKS (Parekh et al., 2015), un método originalmente desarrollado para la detección unicanal de husos. DETOKS utiliza un modelo de descomposición mediante optimización convexa que separa la señal EEG en una componente transitoria, otra componente de baja frecuencia, y por último en una oscilatoria. En este estudio, el algoritmo se aplicó de forma independiente sobre cada derivación bipolar de EEG.

El algoritmo DETOKS utiliza un parámetro denominado λ_2 para modular y regular la componente oscilatoria del modelo. La detección de los husos se realizó sobre la componente oscilatoria obtenida tras la descomposición (ver Figura 2). Para ello, dicha componente se filtró en la banda característica de los husos (11-16 Hz) mediante un filtro Butterworth de cuarto orden. Posteriormente, la señal oscilatoria filtrada se procesó utilizando el operador de energía de Teager-Kaiser (TKEO), con el objetivo de obtener la envolvente de la actividad oscilatoria. A partir de esta envolvente, se identificaron los máximos locales y se seleccionaron aquellos cuya amplitud superaba un umbral de detección definido por el parámetro $c1$. Una vez detectado cada evento candidato, su inicio y final se determinaron utilizando el umbral relativo equivalente al 10% de la amplitud máxima del pico detectado. Finalmente, solo se consideraron válidos aquellos eventos con una duración comprendida entre 0.5 y 3 segundos.

Tanto el parámetro λ_2 como el umbral de detección $c1$ dependen de las características específicas de las señales EEG, por lo que su ajuste se realizó específicamente para este estudio preliminar. Para ello, se llevó a cabo un proceso de optimización basado en la maximización de la métrica F1-score respecto a las anotaciones clínicas de referencia.




Figura 2: Señales intermedias del detector de husos de sueño correspondientes a una ventana temporal representativa de 10 segundos. Se muestran la señal EEG filtrada entre 0.5 y 30 Hz, la componente transitoria, la componente lenta y las componentes oscilatorias filtradas en la banda 11-16 Hz, junto con sus envolventes obtenidas mediante el operador de energía de Teager-Kaiser (TKEO), para distintos valores del parámetro λ_2 (7, 9 y 11). Puede observarse cómo λ_2 modifica tanto la amplitud como la extensión temporal de la componente oscilatoria asociada al huso detectado.

2.4. Detección multicanal

Para considerar válida la detección multicanal de un huso de sueño, el evento debía estar presente en canales pertenecientes al menos a dos de las tres regiones cerebrales definidas: hemisferio izquierdo (F3-C3 y C3-P3), línea media (Fz-Cz y Cz-Pz) y hemisferio derecho (F4-C4 y C4-P4). Adicionalmente, aquellos eventos detectados con una separación temporal inferior a 1 s fueron fusionados y considerados como un único huso de sueño.

Finalmente, se calculó la densidad de husos de sueño como el número de eventos detectados por minuto de sueño analizado. Esta métrica se obtuvo dividiendo el número total de husos en cada registro entre la duración del segmento de sueño N2 analizado, expresada en minutos.

2.5. Validación del método

La validación del método se realizó comparando los eventos detectados automáticamente con las anotaciones clínicas de referencia, consideradas como *gold standard*. A partir de esta comparación se construyó una matriz de confusión basada en la correspondencia temporal entre eventos detectados y los anotados manualmente.

Se consideró un verdadero positivo (TP) cuando un huso detectado por el algoritmo coincidía temporalmente con un evento anotado por la experta, utilizando un criterio mínimo de solapamiento del 50%. Los falsos positivos (FP) correspondieron a eventos detectados automáticamente que no presentaban correspondencia con las anotaciones de referencia, mientras que los falsos negativos (FN) fueron aquellos husos anotados manualmente que no fueron detectados por el algoritmo.

A partir de la matriz de confusión se calcularon las métricas de precisión, sensibilidad y medida F1-score. Esta última se utilizó como principal indicador del rendimiento global del sistema, al combinar de forma equilibrada la precisión y la sensibilidad del detector.

$$\text{Precisión} = \frac{TP}{TP+FP} \quad (1)$$

$$\text{Sensibilidad} = \frac{TP}{TP+FN} \quad (2)$$

$$f1 - score = 2 \cdot \frac{\text{Precisión} \cdot \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}} \quad (3)$$

3. Resultados

3.1. Detección automática de husos de sueño

La Figura 3 muestra un ejemplo de detección de husos del sueño mediante el criterio multicanal propuesto. Puede observarse cómo los eventos validados coinciden con la presencia simultánea de actividad oscilatoria en múltiples derivaciones EEG.




Figura 3: Ejemplo de detección multicanal de husos del sueño en las derivaciones bipolares analizadas. Las señales EEG filtradas (0.5–30 Hz) se muestran en negro, la componente oscilatoria (11–16 Hz) en lila y la señal binaria de detección en gris. Las regiones sombreadas en lila corresponden a los eventos validados mediante el criterio multicanal.

3.2. Optimización de los parámetros λ_2 y c_1

Para la optimización de los parámetros del algoritmo se realizó un barrido de valores de λ_2 (peso de la componente oscilatoria) entre 7 y 11, con incrementos de una unidad, y de c_1 (umbral de detección) entre 0.001 y 1.2, utilizando incrementos no equidistantes. En total, se evaluaron 75 combinaciones de parámetros sobre el conjunto de los siete registros analizados. La Figura 4 muestra el F1-score global obtenido para cada combinación evaluada. Los resultados evidencian una interdependencia entre ambos parámetros, observándose un patrón diagonal en el mapa de calor. Este comportamiento sugiere que incrementos en el valor de λ_2 pueden compensarse mediante ajustes en el umbral c_1 , manteniendo un rendimiento similar del detector. La mejor combinación de parámetros se obtuvo para $\lambda_2 = 10$ y $c_1 = 0.1$, alcanzando un F1-score aproximado de 0.63.






Figura 4: Mapa de calor del F1-score en función de los parámetros λ_2 y c_1 .

De manera complementaria, la Figura 5 muestra las curvas precisión-sensibilidad (PR) obtenidas para los distintos valores de λ_2 evaluados. A diferencia del comportamiento teórico ideal, estas curvas presentan trayectorias no monótonas e irregulares. Este comportamiento puede deberse al mismo post-procesamiento del detector. En particular, la fusión de eventos cercanos (separados por menos de 1 s) y el posterior filtrado por duración (0.5–3 s) introducen efectos no lineales en la respuesta del sistema. En este contexto, un incremento en la detección de candidatos da lugar a la fusión de eventos adyacentes, generando husos de duración excesiva que son finalmente descartados, lo que repercute simultáneamente en la sensibilidad y a la precisión en determinados puntos de funcionamiento. El rendimiento ideal se sitúa en la coordenada (1,1) (Miao et al., 2022), correspondiente a una precisión y sensibilidad perfectas. En este sentido, el análisis de las curvas confirma que la configuración $\lambda_2 = 10$ y $c_1 = 0.1$ es la más robusta, al presentar la menor distancia euclídea a dicho punto ideal (0.530).

Para evaluar la capacidad de generalización del detector, se realizó una validación cruzada *leave-one-out* (LOO) sobre los siete registros disponibles. Los resultados fueron consistentes con los del análisis global, por lo que se mantuvo la configuración seleccionada.



El análisis individual de los siete pacientes utilizando la configuración óptima ($\lambda_2 = 10$, $c1 = 0.1$) junto con la estrategia multicanal se presenta en la Figura 6. Los resultados muestran una variabilidad notable entre sujetos, con valores de F1-score comprendidos entre 0.346 y 0.738, y una media global de 0.581. Como puede observarse en el diagrama de barras, existe una relación entre el número de husos anotados por la experta (barra gris) y el rendimiento del detector (barra lila). Los sujetos con mayor densidad de eventos, como los pacientes B (107 marcas) y D (110 marcas), presentan los mejores rendimientos de detección. Por el contrario, el sujeto C, con solo 20 husos anotados, obtiene el rendimiento más bajo.



Con el objetivo de evaluar la plausibilidad fisiológica de las detecciones automáticas, se analizó la densidad de husos identificados por el sistema en cada sujeto. Como se muestra

Aunque se observaron discrepancias individuales entre las detecciones automáticas y las anotaciones realizadas por la experta, el comportamiento general del sistema fue consistente. En los sujetos A, B y C, el algoritmo mostró una mayor sensibilidad, detectando un número superior de husos respecto a la experta, mientras que en los sujetos D, E y G el comportamiento fue más restrictivo. A pesar de estas discrepancias, la mayoría de las densidades obtenidas se situaron dentro de los rangos descritos en la literatura para población pediátrica sana mayor de tres años (Gruber et al., 2016).

Comparación de la densidad de husos de sueño por sujeto

Sujeto	Método automatico (husos de sueño/min)	Método manual (husos de sueño/min)
A	4.1	2.3
B	7.6	5.1
C	3.1	1.0
D	4.1	5.2
E	3.5	4.3
F	0.9	1.0
G	1.4	2.9

4. Discusión

Desde el punto de vista técnico, uno de los aspectos más relevantes observados fue el comportamiento no monótono de las curvas precisión-sensibilidad. Este fenómeno parece estar relacionado con la etapa de post-procesado. Al incrementar la sensibilidad del detector, los eventos próximos temporalmente se fusionan, generando husos con duraciones superiores a los 3 segundos. Dado que esos eventos exceden los criterios

clínicos establecidos, son descartados por el filtro de duración, provocando una reducción simultánea tanto de la precisión como de la sensibilidad.

El análisis individual mostró además una variabilidad considerable entre sujetos, reflejando la heterogeneidad propia de la actividad fusiforme en pacientes pediátricos con epilepsia focal. En general, los registros con una mayor densidad de husos facilitaron la detección automática, y obtuvieron mejores métricas de rendimiento, mientras que aquellos con menor número de eventos resultaron más sensibles a pequeñas discrepancias temporales entre las anotaciones manuales y las anotaciones automáticas. Las densidades estimadas por el detector oscilaron entre 1 y 8 husos/min. Aunque estos valores se encuentran próximos a los descritos en población pediátrica sana, algunos sujetos presentaron densidades claramente inferiores (Gruber et al., 2016). Este hallazgo, observado tanto con las anotaciones manuales como con las detecciones automáticas, es coherente con estudios previos que han descrito una reducción de la actividad fusiforme en determinadas formas de epilepsia infantil (Chen et al., 2023).

La incorporación de una estrategia multicanal constituye otro de los puntos fuertes del trabajo. A diferencia de los enfoques monocanales tradicionales, esta aproximación permite integrar información espacial de diferentes regiones cerebrales, reduciendo la influencia de artefactos localizados y de detecciones aisladas en derivaciones individuales. Esta característica resulta especialmente relevante en el contexto de la epilepsia pediátrica, donde la morfología y distribución espacial de los husos puede variar notablemente entre pacientes. Además, disponer de un método automático y reproducible facilita la cuantificación objetiva de parámetros como la densidad, duración y distribución topográfica de los husos, abriendo una puerta a futuros estudios orientados a analizar su relación con variables clínicas, cognitivas y evolutivas.

No obstante, el estudio presenta varias limitaciones que deben considerarse. En primer lugar, el tamaño de la muestra es reducido ($n=7$), lo que limita la capacidad de generalización de los resultados. Asimismo, la validación se realizó utilizando las anotaciones de una única especialista, lo que podría introducir sesgos asociados al criterio individual de anotación. Además, la optimización de los parámetros se realizó de forma global y no personalizada para cada sujeto, por lo que es posible que un ajuste individual pudiera mejorar el rendimiento del detector en algunos casos. En futuros trabajos sería conveniente ampliar la cohorte de pacientes, incorporar anotaciones realizadas por múltiples expertos y estudiar la optimización personalizada de los parámetros para obtener una evaluación más robusta y representativa del rendimiento del sistema.

Agradecimientos

Este trabajo ha sido financiado por los proyectos de I+D+i PID2024-155526OB y PID2023-150654OB-I00, financiado por el Ministerio de Ciencia, Innovación y Universidades (MICIU), la Agencia Estatal de Investigación

(AEI/10.13039/501100011033) y el Fondo Europeo de Desarrollo Regional (FEDER), “Una manera de hacer Europa”.

Referencias

- Chen, C., Wang, K., Belkacem, A.N., Lu, L., Yi, W., Liang, J., Huang, Z., Ming, D., 2023. A comparative analysis of sleep spindle characteristics of sleep-disordered patients and normal subjects. *Frontiers in Neuroscience* 17, 1110320. DOI: 10.3389/fnins.2023.1110320.
- Fisher, R.S., Acevedo, C., Arzimanoglou, A., et al., 2014. ILAE official report: A practical clinical definition of epilepsy. *Epilepsia* 55(4), 475–482. DOI: 10.1111/EPL12550
- Fortini, S., Beghi, E., Canevini, M.P., et al., 2021. More than one self-limited epilepsy of childhood in the same patient: A multicenter study. *Epilepsy Research* 177, 106768. DOI: 10.1016/J.EPLEPSYRES.2021.106768.
- Gallotto, S., Seeck, M., 2023. EEG biomarker candidates for the identification of epilepsy. *Clinical Neurophysiology Practice* 8, 32–41. DOI: 10.1016/j.cnp.2022.11.004.
- Gruber, R., Wise, M.S., 2016. Sleep spindle characteristics in children with neurodevelopmental disorders and their relation to cognition. *Neural Plasticity* 2016, 4724792. DOI: 10.1155/2016/4724792.
- Iber, C., Ancoli-Israel, S., Chesson, A.L., 2015. *The AASM manual for the scoring of sleep and associated events*. American Academy of Sleep Medicine, Westchester, IL, USA.
- Kramer, M.A., Stoyell, S.M., Chinappen, D., Ostrowski, L.M., Spencer, E.R., Morgan, A.K., Emerton, B.C., Jing, J., Westover, M.B., Eden, U.T., Stickgold, R., Manoach, D.S., Chu, C.J., 2021. Focal sleep spindle deficits reveal focal thalamocortical dysfunction and predict cognitive deficits in sleep activated developmental epilepsy. *The Journal of Neuroscience* 41(8), 1816–1829. DOI: 10.1523/JNEUROSCI.2009-20.2020.
- McLaren, J.R., Luo, Y., Kwon, H., Shi, W., Kramer, M.A., Chu, C.J., 2023. Preliminary evidence of a relationship between sleep spindles and treatment response in epileptic encephalopathy. *Annals of Clinical and Translational Neurology* 10(9), 1513–1524. DOI: 10.1002/ACN3.51840.
- Mei, N., Grossberg, M.D., Ng, K., Navarro, K.T., Ellmore, T.M., 2017. Identifying sleep spindles with multichannel EEG and classification optimization. *Computers in Biology and Medicine* 89, 441–448. DOI: 10.1016/J.COMPBIOMED.2017.08.030.
- Miao, J., Zhu, W., 2022. Precision-recall curve (PRC) classification trees. *Evolutionary Intelligence* 15(3), 1545–1569. DOI: 10.1007/s12065-021-00565-2.
- Organización Mundial de la Salud, 2025. Epilepsia. Organización Mundial de la Salud. Disponible en: <https://www.who.int/es/news-room/factsheets/detail/epilepsy>
- Parekh, A., Selesnick, I.W., Rapoport, D.M., Ayappa, I., 2015. Detection of K-complexes and sleep spindles (DETOKS) using sparse optimization. *Journal of Neuroscience Methods* 251, 37–46. DOI: 10.1016/j.jneumeth.2015.04.006.
- Purcell, M., Manoach, D.S., Demanuele, C., et al., 2017. Characterizing sleep spindles in 11,630 individuals from the National Sleep Research Resource. *Nature Communications* 8(1), 1–16. DOI: 10.1038/ncomms15930.
- Schönauer, M., Pöhlchen, D., 2018. Sleep spindles. *Current Biology* 28(19), R1129–R1130. DOI: 10.1016/j.cub.2018.07.035.
- Shlobin, N.A., Singh, G., Newton, C.R., Sander, J.W., 2021. Classifying epilepsy pragmatically: Past, present, and future. *Journal of the Neurological Sciences* 427, 117515. DOI: 10.1016/J.JNS.2021.117515.
- Tamamoto, Y., Fujie, T., Umimoto, K., Nakamura, H., 2024. Factors affecting discrepancies between scorers in manual sleep spindle detections in single-channel electroencephalography in young adult males. *Frontiers in Sleep* 3. DOI: 10.3389/frsle.2024.1427540.
- Wendt, S.L., Welinder, P., Sorensen, H.B.D., Peppard, P.E., Jennum, P., Perona, P., Mignot, E., Warby, S.C., 2015. Inter-expert and intra-expert reliability in sleep spindle scoring. *Clinical Neurophysiology* 126(8), 1548–1556. DOI: 10.1016/j.clinph.2014.10.158.
- Wirrell, E.C., Nabbout, R., Scheffer, I.E., et al., 2022. Methodology for classification and definition of epilepsy syndromes with list of syndromes: Report of the ILAE task force on nosology and definitions. *Epilepsia* 63(6), 1333–1348. DOI: 10.1111/EPL17237.
- Zhang, W., Xin, M., Song, G., Liang, J., 2023. Childhood absence epilepsy patients with cognitive impairment have decreased sleep spindle density. *Sleep Medicine* 103, 89–97. DOI: 10.1016/j.sleep.2023.01