

Clasificación de los desórdenes del sueño a través de polisomnogramas usando un algoritmo de aprendizaje profundo

Marco Antonio Rodríguez Castrejón, Leticia Ortega Máynez,
Nelly Gordillo Castillo, José Manuel Mejía Muñoz,
José David Díaz Román

Universidad Autónoma de Ciudad Juárez,
Instituto de Ingeniería y Tecnología, Maestría en Ingeniería Eléctrica,
México

al199048@alumnos.uacj.mx, {lortega, nelly.gordillo,
jose.mejia, david.roman}@uacj.mx

Resumen. La presente investigación tiene como objetivo la clasificación y/o predicción de los siguientes trastornos del sueño: epilepsia nocturna del lóbulo frontal, apnea obstructiva del sueño, movimiento periódico de piernas y desorden de comportamiento REM) por medio de algoritmos de aprendizaje profundo con señales extraídas de polisomnogramas. Se consultaron las bases de datos públicas y privadas: CAP Sleep Database y Wisconsin Sleep Cohort (WSC), de las cuales se extrajeron polisomnogramas (PSG) de diez pacientes de cada trastorno además de 10 sin algún trastorno, de los cuales se utilizó las señales EEG, ECG y SaO₂/SpO₂. Primero se filtró el ruido de las señales por medio de un filtro FIR exceptuando la señal de oxígeno, posteriormente se segmentaron las señales en ventanas de 20 segundos para ser codificadas en imágenes por medio de funciones de transformación de series en el tiempo, las cuales alimentan a una red neuronal convolucional recurrente. Como resultado preliminar se obtuvo una precisión mayor del 90 %. Como conclusión podemos observar que esta investigación brinda una herramienta a los especialistas del área del sueño (psiquiatría, neurología, neurofisiología, etc.) para clasificar y diagnosticar los trastornos del sueño, ahorrándoles tiempo y automatizando el proceso con precisión sin embargo es necesario trabajar con más datos del PSG para obtener mejores resultados.

Palabras clave: Aprendizaje profundo, redes convolucionales recurrentes, apnea del sueño, epilepsia nocturna del lóbulo frontal, movimiento periódico de piernas, desorden de comportamiento REM, codificación series en el tiempo.

Classification of Sleep Disorders through Polysomnograms Using a Deep Learning Algorithm

Abstract. This research aims to classify and/or predict the following sleep disorders: nocturnal lobe epilepsy frontal lobe, obstructive sleep apnea, periodic

leg movement, and REM behavior disorder) using deep learning algorithms with signals extracted from polysomnograms. Public and private databases were consulted: CAP Sleep Database and Wisconsin Sleep Cohort (WSC), from which polysomnograms (PSG) were extracted from ten patients with each disorder in addition to 10 without any disorder, of which EEG signals were used ECG and SaO₂/SpO₂. First, the noise of the signals was filtered by means of an FIR filter, except for the oxygen signal, then the signals were segmented into 20-second windows to be encoded in images by means of time series transformation functions, which feed to a recurrent convolutional neural network. As a preliminary result, an accuracy greater than 90% was obtained. In conclusion, we can observe that this research provides a tool for specialists in the area of sleep (psychiatry, neurology, neurophysiology, etc.) to classify and diagnose sleep disorders, saving them time and automating the process with precision. However, it is necessary to work with more PSG data for better results.

Keywords: Deep learning, recurrent convolutional networks, apnea of sleep, nocturnal epilepsy of the frontal lobe, movement leg newspaper, REM behavior disorder, time series coding.

1. Introducción

Día a día los trastornos de sueño se vuelven más frecuentes conforme el ritmo de vida se hace más acelerado, el estrés aumenta, la población crece, el clima cambia, nuevas enfermedades aparecen, se incrementan los déficits alimenticios, etc.

Este tipo de trastornos se pueden presentar desde la etapa neonatal hasta la adultez. El sueño es considerado un proceso fisiológico de vital importancia para la salud integral de los seres humanos. Además, la falta de sueño es detonante de alteraciones en el procesamiento y retención de la memoria.

Los especialistas del área se enfrentan a tener que diagnosticar diversos trastornos del sueño tales como: narcolepsia, insomnio, bruxismo, epilepsia nocturna del lóbulo frontal, apnea obstructiva del sueño, movimientos periódicos de extremidades, trastornos durante la fase REM, entre otros [1, 2].

Los cuales, para poder detectarlos y diagnosticarlos, es necesario recurrir a la obtención de polisomnografía, que es la representación de un estudio de señales de diversos canales conectados al paciente por electrodos en diferentes zonas del cuerpo mientras se está dormido, como es en la parte superior, frontal y lateral de la cabeza [3].

Todo esto en un cuarto controlado; este proceso conlleva horas de obtención de las señales y debe monitorearse en todo momento, siendo el tiempo una limitante en el estudio. Gracias al desarrollo de métodos de aprendizaje profundo [4], algunas tareas de la sociedad moderna que antes eran complejas ahora son fáciles de hacer, tales como: identificar objetos en imágenes, transcribir voz en texto, encontrar nuevos productos que simpaticen con los intereses de los usuarios, tareas de clasificación, etc.

Para realizar lo anterior, existen varias arquitecturas de redes neuronales: las multi-capas de perceptrones, que es la arquitectura más antigua y simple de redes neuronales, la CNN (convolutional neuronal network) basada en capas convolucionales, de uso muy

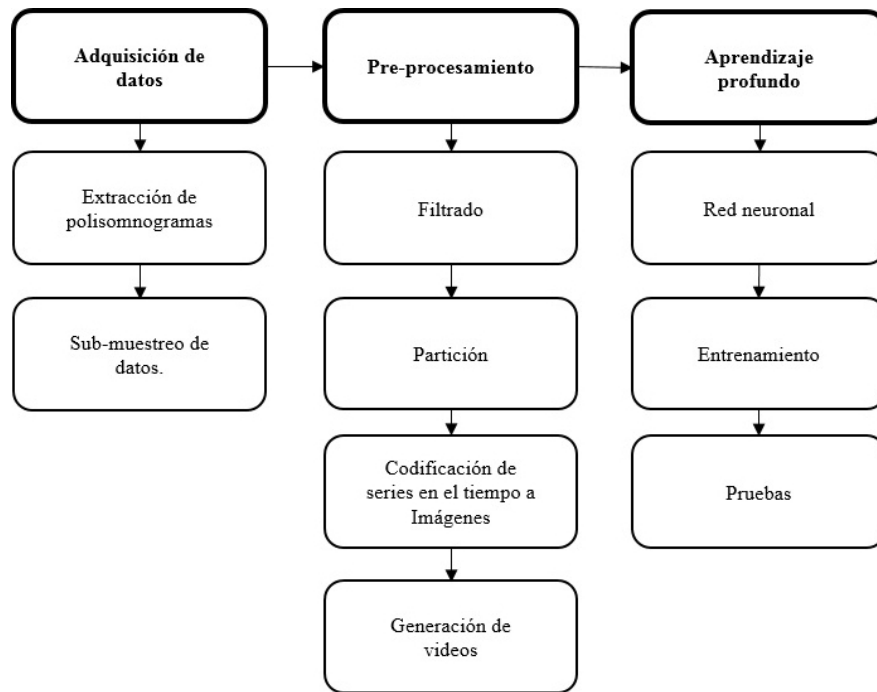


Fig. 1. Diagrama a bloques de la metodología.

común en procesamiento de imágenes y redes neuronales recurrentes usadas para datos secuenciales como texto o series en el tiempo [5].

En este proyecto se desarrollará una arquitectura de aprendizaje profundo con redes neuronales convolucionales para la clasificación de trastornos de sueño. Para el entrenamiento será necesario extraer los polisomnogramas de dos bases de datos públicas y privadas seleccionadas de la internet [6, 7, 8, 9].

Las señales digitales obtenidas serán pre-procesadas digitalmente por medio de filtros que nos ayudan a mejorar la señal final para a posteriori alimentar la red neuronal. Los propósitos de este proyecto son: brindar una herramienta a especialistas del área, para que puedan clasificar y diagnosticar los trastornos del sueño ahorrándoles tiempo y automatizando el proceso con alta precisión, así como avanzar en el conocimiento generado en el tema.

2. Trabajos relacionados

En 2019 Chowdhury, et al. [10] diseñaron una arquitectura de aprendizaje profundo para diagnosticar convulsiones por medio de señales EEG con una red convolucional 1-D. Está compuesta de una capa convolucional de tamaño kernel 173 con 23 filtros y pasos (strides) de 1, una capa de maxpooling de tamaño 173 y una capa densa con activación sigmoidea; la información fue dividida en segmentos representados con las




Fig. 2. Señal en el dominio del tiempo al dominio de la frecuencia [14].

primeras 5 letras del alfabeto donde A y B pertenecen a participantes con condiciones normales y C, D, E y F que presentan epilepsias en diferentes categorías.

Los resultados que obtienen para diferenciar cada grupo de clases siempre dan como resultado una precisión del 99.4 ± 0.52 .

En 2020, Wickramaratne y Mahmud [?] propusieron un método de aprendizaje profundo para detectar esfuerzo respiratorio durante el sueño mediante polisomnogramas por medio de las señales EEG, ECG, EOG y SaO₂, muestreadas a 200 Hz, las cuales se les aplicó un filtro FIR y fueron sub-muestreadas a 50 Hz antes de ser inyectadas a una red neuronal recurrente, la arquitectura de la red consta de capas bidireccionales LSTM con funciones de activación ELU y una capa densa distribuida en el tiempo al final.

Esta arquitectura fue aplicada en tres modelos diferentes, uno para la señal EEG y EOG, el segundo para las señales EMG y ECG y el tercero para las EEG y SaO₂ y al final los tres modelos fueron combinados para dar una mejor predicción. Para validar su clasificador utilizaron curvas AUPRC y AUROC las cuales dieron un resultado de 0.59 en el área debajo de la curva de precisión y 0.95 en el área debajo de la curva de recepción de características de operación.

En 2020, Pisano, et al. [12] construyeron una red neuronal convolucional para detectar epilepsia nocturna del lóbulo frontal por medio de señales EEG muestreadas a 256 Hz, la arquitectura de la red neuronal utilizada se basó en una red profunda residual compuesta de capas convolucionales, max pooling y average pooling.

Dentro de cada capa convolucional se agregó una capa de dropout de 0.20 para evitar sobre entrenamiento, y el algoritmo que se utilizó para optimizar el entrenamiento fue el gradiente descendiente estocástico con momento, obtuvieron resultados de precisión entre 0.94 y 0.96.




Fig. 3. Respuesta en la frecuencia del Filtro FIR para eliminar ruido en las señales.

En 2020, K. Palani, et al. [13] desarrollaron una red neuronal para detectar epilepsia por medio de imágenes generadas a partir de GASF (Gramian Angular Summation Field).

Utilizando una red convolucional pre-entrenada con los pesos de ImageNet con tres capas convolucionales con función de activación ReLU seguido de una capa de normalización lote (BN) y una capa de MaxPooling con, además, capas densas con activación sigmoidea y finalmente con una capa de clasificación SoftMax binaria para las clases normal y focal. Con este modelo ellos logran obtener una precisión de 0.885 en promedio y área bajo la curva de 0.92 los cuales son superiores a otras arquitecturas como AlexNet, VGG16, VGG19, entre otras.

3. Materiales y métodos

En este capítulo se mostrará la metodología empleada para la realización de esta investigación, así como las herramientas utilizadas.

3.1. Modelado de los datos

Los pasos para el desarrollo de este proyecto fueron: la adquisición de señales de diferentes bases de datos públicas y privadas; pre-procesamiento de los datos para eliminar el ruido, así como convertirlos a imágenes; y el diseño de la red de aprendizaje profundo para la clasificación de los desórdenes del sueño. El diagrama a bloques de la Fig. 1 ilustra la metodología de este proyecto.

3.2. Materiales

Para este proyecto basado en procesamiento digital de señales se utilizaron materiales de hardware y software.

Hardware La computadora que se utilizó para el desarrollo de esta investigación y con la que se realizó todo el pre-procesamiento de las señales adquiridas de las bases de datos, tiene las especificaciones que se muestran a continuación:




Fig. 4. Señales en el dominio de la frecuencia del polisomnograma.




Fig. 5. Imagen resultante de la transformación GASF.

- PC Asus G75vw,
- Procesador Intel Core i7 a 2.4 GHz,
- Memoria RAM de 20 GB,
- Tarjeta de video NVIDIA GEFORCE GTX 660M de 2GB.

Tabla 1. Red neuronal propuesta.

Nombre	Tipo	Tamaño
Conv2D_1	Conv2D	(None, 224, 224, 64)
Conv2D_2	Conv2D	(None, 224, 224, 64)
BatchNorm_1	BatchNormalization	(None, 224, 224, 64)
MaxPool2D_1	MaxPooling2D	(None, 112, 112, 64)
Conv2D_3	Conv2D	(None, 112, 112, 128)
Conv2D_4	Conv2D	(None, 112, 112, 128)
BatchNorm_2	BatchNormalization	(None, 112, 112, 128)
MaxPool2D_2	MaxPooling2D	(None, 56, 56, 128)
GlobalMaxPool2D_1	GlobalMaxPooling2D	(None, 128)
TimeDist_1	TimeDistributed	(None, 5, 128)
GRU_1	GRU	(None, 5, 32)
GRU_2	GRU	(None, 5, 16)
Dense_1	Dense	(None, 1024)
Dense_2	Dense	(None, 512)
Dense_3	Dense	(None, 128)
Dense_4	Dense	(None, 64)
Dense_5	Dense	(None, 5)

Software. Bases de datos Toda la información se extrajo de bases de datos que se encuentran en la red las cuales se enumeran a continuación:

- Base de datos publica: CAP Sleep Database v1.0.0,
- Base de datos privada: Wisconsin Sleep Cohort (WSC).

Python 3.7 El desarrollo de todo el código tanto del pre-procesamiento como el entrenamiento se realiza con el entorno de programación de Python, siendo este un recurso gratuito se ha ido popularizando en los últimos años, las librerías que se utilizaron para ello son:

- NumPy,
- Matplotlib Pyplot,
- MNE io,
- SciPy,
- YASA,
- TensorFlow,
- Keras,
- Scikit-Learn,
- Pandas.

Google Colab El entrenamiento de la red se vuelve una tarea que consume grandes recursos, así como tiempo de ser realizado en una computadora comercial, Google

Tabla 2. Parámetros de entrenamiento.

Número de participantes	10
Imágenes generadas por participante	14390
Duración del video por participante	3 min.
Videos generados por participante	959
Número de clases	5
Número de épocas	100
Índice de aprendizaje	1e-4
Optimizador	Adam
Función de costo	Categorical cross-entropy
CNN Layers/ VGG16	9
RNN Layers/GRU	3
Total de parámetros de entrenamiento	940,037
Tiempo de entrenamiento	6.58 horas

pone a disposición de los usuarios sus computadoras virtuales que cuentan con mayores recursos tecnológicos lo cual hace que la tarea de entrenamiento se vuelva más rápida, algunas de sus especificaciones de la versión Google Colab Pro son:

- GPU T4 y P100,
- Memoria RAM 25 GB,
- 24 horas continuas de entrenamiento.

3.3. Métodos

Adquisición de datos Se obtuvieron polisomnogramas de las bases de datos públicas y privadas: CAP Sleep Database v1.0.0 la cual contiene las clases: nfle (nocturnal frontal lobe epilepsy o epilepsia del lóbulo frontal), normal (sin trastorno), plm (periodic leg movement o movimiento periódico de piernas) y rbd (REM behaviour disorder o desorden de comportamiento REM); y Wisconsin Sleep Cohort (WSC) de la cual se extrajo la clase sdb (sleep disordered breathing o trastorno respiratorio del sueño).

El formato para estos archivos es EDF, el cuál es un estándar europeo para almacenar polisomnogramas. De cada clase se obtuvo diez polisomnogramas de cuatro horas de sueño aproximadamente. Para acceder a ellos se usó la librería de mne de Python con la cual se seleccionó los canales EEG(dos), ECG y SaO2/SpO2 para su posterior procesamiento (Fig. 2).

Pre-procesamiento El pre-procesamiento se llevó a cabo de la siguiente manera:

1. Filtrado de ruido. Se analizaron las señales obtenidas en la sección anterior, pero en el dominio de la frecuencia por medio de la Transformada de Fourier rápida FFT, utilizando la función de numpy fft (ver Fig. 3), y se observa que las frecuencias más importantes están en el rango de 0.5 y 25 Hz. Se diseñó un filtro FIR con los siguientes parámetros:

Tabla 3. Métricas obtenidas para el modelo propuesto, promedio de precisión 0.91.

Trastorno de sueños	Precisión	Exhaustividad	Valor F	Muestras
nfle	0.86	0.90	0.88	97
normal	0.94	0.85	0.89	97
plm	0.81	0.88	0.84	97
rbd	0.93	0.90	0.91	97
sdb	0.99	1.00	0.99	97
Promedio	0.91	0.90	0.90	485




Fig. 6. Curva de entrenamiento, exactitud en entrenamiento de 0.93, exactitud en validación de 0.86.

- Frecuencia de corte baja: 0.5 Hz,
- Frecuencia de corte alta: 25 Hz,
- Número de coeficientes del filtro: 29,
- Tipo de ventana: Hamming.

En la Fig. 4, se observa el filtro que se diseñó para eliminar frecuencias fuera del rango deseado. Una vez creado el filtro se realizó la operación de la convolución con las señales del polisomnograma utilizando la función `signal.convolve` de la librería `scipy`.

2. Partición de datos en ventanas o épocas. Se dividieron los datos del arreglo de señales filtradas en ventanas de 20 segundos de longitud. La función con la que se generó estas ventanas fue `sliding_window` de la librería de `yasa`, con los siguientes parámetros:

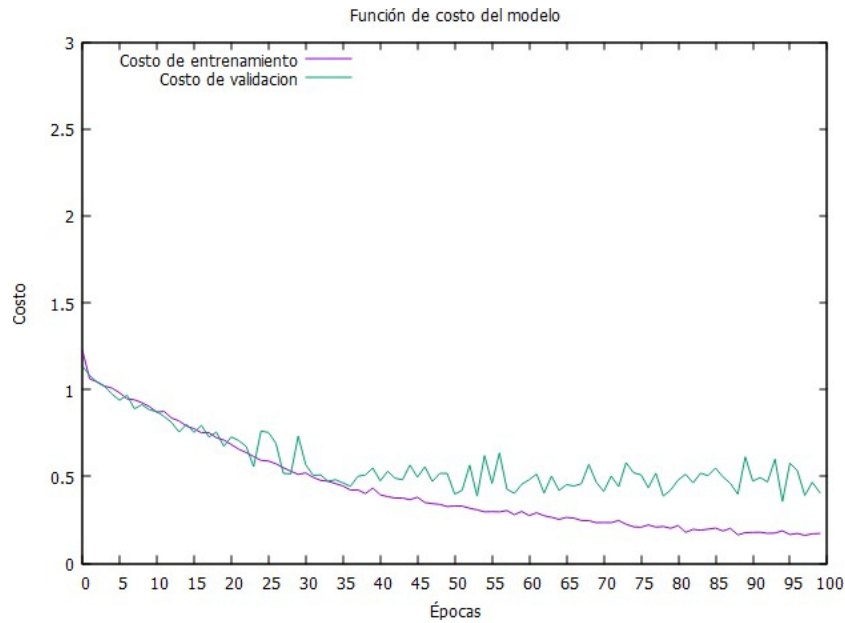


Fig. 7. Curvas de la función de costo, 0.17 en entrenamiento y 0.40 en validación.

- Data = arreglo bidimensional de n canales por puntos en el tiempo,
 - Sf = Frecuencia de muestreo,
 - Window = 20.
3. Codificación de series en el tiempo a imágenes. Este proceso se realizó primero creando el objeto transformerGASF por medio de la clase GramianAngularField de la librería pyts.image con los siguientes parámetros:
 - Image_size = tamaño del arreglo de la serie de datos en el tiempo,
 - Method = summation.

Una vez que se creó el objeto se llamó al método fit_transform pasándole el arreglo bidimensional de la serie en el tiempo, lo que dio como resultado cuatro imágenes diferentes para cada época o ventana en el tiempo, estas fueron agrupadas en una sola imagen utilizando los métodos de la librería matplotlib.pyplot (ver Fig. 5), posteriormente se guardó en un directorio temporal para cada uno de los trastornos.

4. Generación de videos. Para este paso se usó la librería de Open CV de la cual se extrajo el método VideoWriter para escribir los videos a partir de las imágenes generadas en el paso anterior, se especificó el código de video *mp4v el cual dio a la salida videos de extensión .mp4 que se usaron para alimentar la red neuronal.

Aprendizaje profundo

1. Preparación de datos. Los datos fueron preparados antes de entrar en la red neuronal, por medio de la librería ImageDataGenerator y la clase VideoFrameGenerator, primero se realizó aumento de datos con las siguientes características:




Fig. 8. Matriz de confusión, la clase mejor clasificada es sdb mientras que la clase con menor desempeño es la normal.

- Rescale: 1. /255,
- Rotation_range: 0.8,
- Width_shift_range: 0.2,
- Height_shift_range: 0.2,
- Shear_range: 0.2,
- Zoom_range: 0.2,
- Horizontal_flip: True.

Posteriormente se creó el objeto generador de fotogramas(frames) a partir del video con los siguientes parámetros:

- Target_size: 224, 224,
- Color_mode: rgb,
- Batch_size = 16,
- Shuffle: True,
- Nb_frames: 5.

2. Arquitectura. Se diseñó una arquitectura basada en una red recurrente convolucional con capas convolucionales con su respectivo max pooling y activación ReLU, capas

Tabla 4. Comparativa entre el estado del arte actual.

Estudio	Señal	Clasificador	Trastornos del Sueño	Precisión	AUROC
Korkalainen, et al.[15]	EEG(x2), EOG	CNN(1D) LSTM	SDB	NA	NA
Palani, et al.[13]	EEG	Custom CNN	NFLE	0.88	0.92
Sharma, et al.[16]	EEG	Ensemble Bagged and Boosted trees	Normal, Narcolepsia, PLM, SDB, NFLE	0.89	0.99
Modelo propuesto	EEG(x2), ECG, SaO2/SpO2	CNN(2D) GRU	Normal, NFLE, SDB, PLM, RBD	0.91	0.98

GRU, capas densas y una capa densa de activación softmax de 5 unidades para la clasificación de las diferentes clases (Tabla 1).

3. **Compilación y Entrenamiento.** La compilación y el entrenamiento de la red se realizó con los siguientes datos:

- Optimizer: Adam,
- Learning rate: 1e-4,
- Loss: categorical-cross entropy,
- Épocas: 100.

4. Resultados

La red utilizó diez participantes con cinco clases: sdb, nfle, normal, plm y rbd; de cada uno se extrajeron cuatro horas del polisomnograma con cuatro canales de este (EEG, SaO2/SpO2, ECG) lo que generó 14390 imágenes de 20 segundos con traslape de 10 segundos entre cada una, las cuales fueron almacenadas en 959 vídeos de 3 minutos por clase. La red fue alimentada con 80 % del total de los vídeos para entrenamiento, 10 % para validación y 10 % para pruebas, se utilizaron 100 épocas de entrenamiento. Los parámetros de entrenamiento se pueden ver en la Tabla 2.

El resultado en entrenamiento después de 100 épocas alcanza una exactitud de 0.93, mientras que en validación alcanza 0.86 de exactitud (Fig. 6). La curva de la función de costo alcanza a decrecer hasta 0.17 en entrenamiento y hasta 0.40 en validación como se observa en la Fig. 7. Los resultados en las curvas de entrenamiento están por arriba del objetivo mayor a 0.80.

Las métricas de precisión (Precision), sensibilidad (Recall) y el valor F (F1-Score) obtenidas con este modelo se muestran en la Tabla 3, obteniendo un promedio de precisión de 0.91, siendo la mayor precisión en el trastorno sdb con 0.99 y la menor con la condición plm con 0.81.

La matriz de confusión (Fig. 8) muestra que clasifica mejor la clase sdb con 97 de 97, siendo la clase normal la que más confunde con la condición plm. La Tabla 4 muestra la comparación entre el trabajo presentado con otros trabajos realizados en la literatura actual.

5. Conclusiones

El modelo propuesto siendo una red neuronal recurrente, compuesto por capas convolucionales y de memoria (GRU) logró clasificar los cuatro trastornos de sueño y la condición normal propuestos para este trabajo con un promedio de 0.91 en precisión utilizando señales EEG(x2), ECG y SaO2/SpO2 del polisomnograma las cuales son convertidas a imágenes y posteriormente a vídeos de tres minutos de duración.

La red propuesta está diseñada usando capas convolucionales para la extracción de características de las imágenes y capas recurrentes para guardar la información en función del tiempo, el entrenamiento de la red se realizó con apoyo de la plataforma de Google colab. utilizando sus tarjetas gráficas este fue más rápido (7-8 horas).

La metodología propuesta basada en la codificación de señales en el tiempo en imágenes es un método novedoso que basándose en el principio que las redes neuronales han avanzado más en clasificación de imágenes, buscó competir con modelos basados en señales unidimensionales en el tiempo o capas de una dimensión.

El trabajo logra ser una herramienta confiable para la clasificación de trastornos del sueño para los especialistas del sueño ahorrándoles tiempo para analizar toda la señal del polisomnograma.

Esta investigación queda abierta para mejorar la precisión utilizando un mayor número de participantes de entrenamiento, así como también con arquitecturas más modernas. También un trabajo a futuro puede ser su implementación en una interfaz de usuario, llámese computadora o teléfono inteligente por medio de sensores de señales del polisomnograma más ergonómicos y que el usuario final pueda auto-evaluarse.

Referencias

1. Kingman, P. S.: Apnea obstructiva del sueño. Case School of Medicine, Case Western Reserve University (2020)
2. García, J. , Williams, N.: Sleep terrors or nocturnal frontal lobe epilepsy? Sleep. A pediatric perspective. vol. 20, no.2, pp. 1–6 (2011)
3. Biggers, A.: Polysomnography. Healthline (2020)
4. LeCun, Y., Bengio, Y., Hinton, G.: Deep learning. Nature, vol. 521, no. 7553, pp. 436–444 (2015) doi: 10.1038/nature14539
5. Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., De D.: Fundamental concepts of convolutional neural network. In Recent trends and advances in artificial intelligence and internet of Things. Springer, Cham, vol. 172, pp. 519–657 (2020) doi: 10.1007/978-3-030-32644-9_36
6. Terzano, M. G., Parrino, L., Smerieri, A., Chervin, R., Chokroverty, S., Guilleminault, C., Hirshkowitz, M., Mahowald, M., Moldofsky, H., Rosa, A., et al.: Atlas, rules, and recording techniques for the scoring of cyclic alternating pattern (CAP) in human sleep. Sleep medicine, vol. 3, no. 2, pp. 187–199 (2002)
7. Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mietus, J. E., Moody, G. B., Peng, C. K., Mark, R. G., Stanley, H. E.: PhysioBank, physioToolkit, and physioNet: components of a new research resource for complex physiologic signals. Circulation, vol. 101 no. 23, pp. e215—e220 (2000) doi: 10.1161/01.CIR.101.23.e215
8. Zhang, G. Q., Cui, L., Mueller, R., Tao, S., Kim, M., Rueschman, M., Mariani, S., Mobley, D., Redline, S.: The national sleep research resource: towards a sleep data commons. Journal of the American Medical Informatics Association, vol. 25 no. 10, pp. 1351–1358 (2018) doi: 10.1093/jamia/ocy064

9. Young, T., Palta, M., Dempsey, J., Peppard, P. E., Nieto, F. J., Hla, K. M.: Burden of sleep apnea: rationale, design, and major findings of the Wisconsin sleep cohort study. *WMJ: official publication of the State Medical Society of Wisconsin*, vol. 108 no. 5, pp. 246–249 (2009)
10. Chowdhury, T. T., Hossain, A., Fattah, S. A., Shahnaz, C.: Seizure and non-Seizure EEG signals detection using 1-D convolutional neural network architecture of deep learning algorithm. In: 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT), IEEE, pp. 1–4 (2019) doi: 10.1109/ICASERT.2019.8934564
11. Wickramaratne, S. D., Shaad-Mahmud, M. d.: Automatic detection of respiratory effort related arousals with deep neural networks from polysomnographic recordings. In: 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). IEEE, pp. 154–157 (2020) doi: 10.1109/EMBC44109.2020.9176413
12. Pisano, F., Sias, G., Fanni, A., Cannas, B., Dourado, A., Pisano, B., Teixeira, C. A.: Convolutional neural network for Seizure detection of nocturnal frontal lobe epilepsy. *Complexity*, vol. 2020 (2020) doi: 10.1155/2020/4825767
13. Thanaraj, K. P., Parvathavarthini, B., Tanik, U. J., Rajinikanth, V., Kadry, S., Kamalanand, K.: Implementation of deep neural networks to classify EEG signals using gramian angular summation field for epilepsy diagnosis. arXiv:2003.04534 (2020) doi: 10.48550/arXiv.2003.04534
14. Wikipedia: File:FFT-Time-Frequency-View.png (2017)
15. Korkalainen, H., Aakko, J., Nikkonen, S., Kainulainen, S., Leino, A., Duce, B., Afara, I. O., Myllymaa, S., Töyräs, J., Leppänen, T.: Accurate deep learning-based sleep staging in a clinical population with suspected obstructive sleep apnea. *IEEE Journal of Biomedical and Health Informatics*, vol. 24, no. 7, pp. 2073–2081 (2019) doi: 10.1109/JBHI.2019.2951346
16. Sharma, M., Tiwari, J., Patel, V., Acharya, U. R.: Automated identification of sleep disorder types using triplet half-band filter and ensemble machine learning techniques with EEG signals. *Electronics*, vol. 10, no. 13, pp. 1531 (2021) doi: 10.3390/electronics10131531