

Neuropathology Detector in EEG using Higher Order Statistics and Deep Learning

César Seijas ^{*,a} , Sergio Villazana ^a , Guillermo Montilla ^b , Egilda Pérez ^a ,
Ricardo Montilla ^b 

^aCentro de Procesamiento de Imágenes, Facultad de Ingeniería, Universidad de Carabobo, Valencia, Venezuela.

^bYttrium-Technology Corp., Panamá, Panamá.

La selección de este artículo fue realizada en el marco de la Jornada de Investigación de la Escuela de Ingeniería Eléctrica “Prof. César Rodolfo Ruiz” Octubre 2020, siendo la evaluación, arbitraje, aceptación y edición a cargo de Revista Ingeniería UC.

Abstract.- This article presents a neuropathology detector, based on the patient’s electroencephalogram (EEG). Detection is based on HOSA (“High Order Statistical Analysis”) image classification of higher order statistics derived from time series corresponding to EEG of human patients. The classifier is a DL model (“Deep Learning”) with the pretrained CNN (“Convolutional Neural Network”) architecture: Inception. The CNN training and test set are HOSA images of non-linear and non-Gaussian segments, of signals corresponding to the selected channel of the EEG of patients with neuropathologies (specifically, epilepsy) or healthy. The performance of the classifier is very satisfactory, presenting an accuracy of approximately 94 % in the detection of epilepsy.

Keywords: EEG; higher order statistics; deep learning; pre-trained convolutional neural network Inception.

Detector de Neuropatologías en EEG usando Estadísticas de Orden Superior y Aprendizaje Profundo

Resumen.- En el presente artículo se presenta un detector de neuropatologías, a partir del electroencefalograma (EEG) del paciente. La detección se basa en la clasificación de imágenes de HOSA (siglas en inglés para análisis de estadísticas de orden superior o “High Order Statistical Analysis”) derivadas de series de tiempo correspondientes a EEG de pacientes humanos. El clasificador es un modelo de aprendizaje profundo DL (“Deep Learning”) con la arquitectura de la CNN (Red Neuronal Convolutiva o “Convolutional Neural Networks”) pre-entrenada: “Inception”. El conjunto de entrenamiento y prueba de la CNN son imágenes de HOSA, que representan los cumulantes de tercer orden de segmentos no lineales y no gaussianos, de señales correspondientes al canal seleccionado del EEG de pacientes con neuropatologías (específicamente, epilepsia) o sanos. El desempeño del clasificador es muy satisfactorio, presentando una exactitud de aproximadamente 94 % en la detección de epilepsia.

Palabras clave: EEG; estadísticas de orden superior; aprendizaje profundo; red neuronal convolutiva pre-entrenada Inception.

Recibido: 22 de octubre, 2020.

Aceptado: 14 de diciembre, 2020.

1. Introducción

El procesamiento de señales electrofisiológicas, con fines diagnósticos, ha tenido grandes avances

en el campo de la medicina y actualmente la incorporación de la inteligencia artificial (IA), y particularmente aprendizaje profundo DL (siglas en inglés para “Deep Learning”) está produciendo importantes desarrollos en el tratamiento de desórdenes neurológicos [1, 2, 3]. En general, las señales se captan mediante sensores que traducen los fenómenos electrofisiológicos, en débiles potenciales eléctricos, que posterior a un

* Autor para correspondencia:
Correo-e: cseijas@uc.edu.ve (C. Seijas)

adecuado procesamiento analógico, se convierten en señales digitales compatibles con análisis mediante el computador.

El Electroencefalograma (EEG) es el registro de las señales de la actividad electrofisiológica de las células cerebrales, conocidas como neuronas. Esta actividad es el resultado de la superposición de múltiples impulsos eléctricos (potencial de acción) [4, 1], generados en las neuronas, producto del intercambio iónico a través de la membrana celular (proceso de difusión iónica). El EEG se obtiene mediante la colocación de un conjunto de electrodos en el cráneo, sobre la región del cuero cabelludo. El sistema internacional de ubicación de electrodos 10-20 [5] genera un mapa de puntos separados 10 o 20 %, del área total bajo registro, con una nomenclatura asociada al nombre de la región craneal cubierta.

La interpretación correcta del EEG, por parte del experto, permite detectar y diagnosticar diferentes neuropatologías o estados neurológicos tales como: alteraciones del sueño, epilepsia, nivel de anestesia, presencia de actividad cerebral o incluso muerte. La epilepsia es una neuropatía muy común, que se manifiesta en repentinas ráfagas de actividad eléctrica, no controlada, en algunas regiones de la corteza cerebral. Los pacientes epilépticos sufren de ataques recurrentes, con manifestaciones que varían desde leves sensaciones anormales, hasta cambios impredecibles que alcanzan la pérdida inmediata de la consciencia y convulsiones [6]. Esta neuropatología afecta aproximadamente al 1 % de la población mundial. Las Figuras 1a y 1b, generadas con el software para procesamiento de señales electroencefalográficas EEGLAB [7], corresponden a segmentos de señales de los canales de EEG, para un paciente de control (sin la neuropatía) y uno epiléptico, respectivamente.

El objetivo del presente estudio, es desarrollar un nuevo método, para la detección de esta neuropatología, a partir de información derivada del EEG. Lo anterior, en aras de mejorar la calidad de vida de un paciente epiléptico o incluso de personas que desconocen de su predisposición a padecer de este mal, En el presente artículo se describe el desarrollo de un sistema automatizado para detectar epilepsia, a partir del EEG, usando


herramientas de IA y HOSA [8].

El sistema basado en DL, usa un clasificador construido con la CNN pre-entrenada Inception [9], pero especializado, para detección de epilepsia en el EEG. El clasificador discrimina rasgos subyacentes en imágenes HOSA, obtenidas a partir de las señales de EEG de pacientes epilépticos y de control. Como se afirma en estudios previos y se verifica, en este estudio, las señales de EEG son series de tiempo, altamente no lineales y no gaussianas, que, en consecuencia, exhiben estadísticas de orden superior. En el caso específico, de las estadísticas: momentos y cumulantes de orden mayor al tercero, estas métricas se manifiestan como señales hiperdimensionales. La estrategia planteada, en el sistema desarrollado, es detectar epilepsia en los EEG, usando estas señales, que son bidimensionales para los cumulantes de tercer orden [8, 10, 11] y debidamente etiquetadas como epilépticas o de control, como las imágenes de entrenamiento del clasificador.


2. Antecedentes

Existen numerosos e interesantes estudios, que han reportado aplicaciones de DL en EEG. A continuación, se mencionan algunos trabajos en el asunto, objeto del presente artículo: Craik *et al.* [12], hacen una revisión de la literatura, sobre aplicaciones con DL, en el proceso de clasificación de EEG. La consulta ubicó y analizó 90 publicaciones, en bases de datos de sitios especializados como son: “Web of Science” y “PubMed”. En su revisión, presentan, para cada documento estudiado, aspectos fundamentales como son: arquitectura de la red empleada (CNN, redes recurrentes, etc.), tipo de tarea abordada por la red, esto es: detección de neuropatías, clasificación de emociones, predicción de ataques, entre otras posibles tareas, y concluyen presentando, para cada caso analizado, los logros y resultados alcanzados en cada publicación consultada.

Los autores, Raghavendra *et al.* [3], también presentan una revisión exhaustiva, pero específicamente, en el tema del diagnóstico automatizado mediante IA, aplicada a señales e imágenes



(a) Canales de EEG para un paciente de control



(b) Canales de EEG para un paciente epiléptico

Figura 1: Canales de EEG, para (a) un paciente de control y (b) un paciente epiléptico

electrofisiológicas, de 5 trastornos neurológicos seleccionados; la revisión abarca las últimas 2 décadas. Las neuropatías consideradas son: epilepsia, enfermedad de Parkinson, enfermedad de Alzheimer, esclerosis múltiple y accidente cerebrovascular isquémico. En el estudio, los autores analizan y comparan, los diferentes métodos de extracción y selección de rasgos, las técnicas de reducción de dimensionalidad usadas, y las técnicas de clasificación.

En [13], Golmohammadi *et al.*, describen el desarrollo de un sistema automatizado de análisis de EEG, de alto rendimiento, basado en principios de aprendizaje de máquinas ML (para “Machine Learning”) y manejo de gran volumen de datos (“big data”). El sistema desarrollado es una arquitectura híbrida, que incorpora contexto temporal y espacial; integrando HMM (para “Hidden Markov Models” o modelos ocultos de

Márkov) para la decodificación secuencial de eventos en el EEG, y postprocesamiento espacial, basado en DL (CNN). Los modelos del sistema, fueron entrenados y evaluados con la base de datos de EEG, TUH (“Temple University Hospital”). Los autores reportan que el sistema registra y clasifica patrones de interés clínico, de la actividad cerebral, como son: picos y ondas agudas, descargas epileptiformes periódicas generalizadas, descargas epileptiformes periódicas lateralizadas; además de detectar movimiento de los ojos, artefactos y actividad de fondo [2, 6]. Según los resultados, presentados en el artículo, el sistema exhibe una sensibilidad por encima del 90 % mientras mantiene una especificidad por debajo del 5 %.

El trabajo de Gegein *et al.*, presentado en [14], también corresponde a una plataforma híbrida (como [13]), pero en este caso usada como clasificador para discriminar entre EEG patológico

y no patológico. La plataforma usa una TCN (siglas en inglés para “Temporal Convolutional Network”) como extractora de rasgos secuenciales y una CNN, para rasgos espaciales; la base de datos usada, similar a [13] también es TUH. La TCN, usa como vector de rasgos, los cálculos derivados de aplicar las operaciones: Transformada Discreta de Fourier, Transformadas Wavelet Continua y Discreta y características de conectividad entre electrodos basadas en la Transformada Hilbert; las operaciones se aplicaron a segmentos de un canal seleccionado del EEG. Los autores manifiestan, que los resultados reportados, colocan el marco de decodificación propuesto, basado en rasgos, al mismo nivel que las redes neuronales profundas de última generación. El rango de precisión, entre ambos, es del 81 al 86 %.

Mahmoodian *et al.* [10], predicen ataques epilépticos, con un modelo a ML, a partir de diez características multivariantes no lineales, extraídas del biespectro cruzado [8]. Las estadísticas mencionadas, se emplearon, como vectores de entrenamiento de una SVM (siglas en inglés para “Support Vector Machines”) [11, 15], que discrimina estados preictales, de los interictales [6]. El predictor a SVM, en referencia, obtuvo una sensibilidad del 100 % y una FPR False Positive Rate” o tasa de falsos positivos) promedio de 0,044; utilizando el conjunto de datos de “Predicción de ataques epilépticos de Frieiburg” (University of Freiburg, 2008) La alta sensibilidad y muy bajo FPR, en comparación con otros estudios, evidencian la excelente capacidad del método, basado en HOSA, para analizar las señales de EEG epilépticas.

En [16], Yean *et al.*, estudiaron la no gaussianidad en la señal de EEG emocional (alegría, desagrado o neutro) de pacientes con accidente cerebrovascular y pacientes de control. La no gaussianidad se determinó, mediante el cálculo de las métricas estadísticas [8]: asimetría (skewness”) y kurtosis. La función de distribución estimada, del EEG emocional, fue simétricamente no gaussiana tanto para los grupos de accidente cerebrovascular como para los de control. En particular, se encontró que, la distribución de EEG no gaussiana, es más frecuente en pacientes de control, que en aquellos

con accidente cerebrovascular.

En [11], el autor clasifica EEG en epilépticos o normales, con un clasificador a SVM, entrenado con vectores conformados por dos rasgos extraídos de la respuesta frecuencial de orden superior: la bicoherencia y la máxima potencia. Los rasgos se obtuvieron, mediante la aplicación de HOSA, a la señal del canal seleccionado, de los EEG, de los pacientes en estudio. El criterio de selección de un canal del EEG, fue elegir el canal con máxima potencia, en toda la banda de actividad electrofisiológica cerebral [2]. La exactitud lograda con el clasificador fue de 92 %.

3. Fundamentos teóricos


El objetivo de este artículo es el desarrollo de un sistema, que usa IA, en el proceso de detección de neuropatías, específicamente epilepsia, a partir de EEG. El sistema usa un clasificador basado en la CNN pre-entrenada Inception, que se debe entrenar (especializar) en la detección de rasgos epilépticos en un EEG.

El conjunto de datos de entrenamiento corresponde a señales bidimensionales, convertidas a imágenes y obtenidas del procesamiento, basado en HOSA, de segmentos, de la serie de tiempo que representa la actividad eléctrica de un canal (de los múltiples canales) del EEG. El uso de HOSA trae a colación, una discusión importante, en el tema del procesamiento de las señales del EEG, la cual es: deben estas señales, ser estudiadas, con base a una naturaleza lineal y determinística, o deben ser procesadas como sistemas complejos y caóticos, o si, más bien, deben considerarse predominante estocásticas.

Con base a lo último expuesto, es preciso validar si los segmentos usados para la generación de las imágenes de entrenamiento, son efectivamente no gaussianas y no lineales [18, 17]. En esta sección, se discuten los fundamentos teóricos de HOSA, de la prueba de linealidad y gaussianidad de señales y de la arquitectura CNN Inception.

3.1. Análisis no lineal utilizando estadísticas de orden superior

Las señales gaussianas y lineales se caracterizan, completamente, con los momentos estadísticos



(a) Cumulante de tercer orden de un canal de EEG, para un paciente de control (b) Cumulante de tercer orden de un canal de EEG, para un paciente epiléptico

Figura 2: Cumulantes de tercer orden de un canal de EEG

de primer y segundo orden (media y varianza). Las señales de EEG son altamente no lineales y no gaussianas [10, 16, 11, 17]. Los momentos y cumulantes se definen por las siguientes expresiones:

$$C_{2x}(k) = E\{x^*(n)x(n+k)\}, \quad (1)$$

$$C_{3x}(k,l) = E\{x^*(n)x(n+k)x(n+l)\}, \quad (2)$$

$$\begin{aligned} C_{4x}(k,l,m) = & E\{x^*(n)x(n+k)x(n+l)x^*(n+m)\} \\ & - C_{2x}(k)C_{2x}(l-m) \\ & - C_{2x}(l)C_{2x}(k-m) \\ & - M_{2x}^*(m)M_{2x}(k-l), \end{aligned} \quad (3)$$

$$M_{2x}(m) = E\{x(n)x(n+m)\}. \quad (4)$$

Las ecuaciones (1), (2) y (3), corresponden a los cumulantes de segundo, tercer y cuarto orden respectivamente, mientras que la ecuación (4), define al momento de segundo orden $C_{2x}(m)$, que aparece en la ecuación (3); el superíndice * en $x^*(n)$ denota la señal $x(n)$ compleja conjugada, y los índices: k, l, m son retardos en cada dimensión espacial. Obsérvese que $C_{2x}(m)$ es igual a $C_{2x}(k)$ en el caso de series de tiempo reales [8, 10] y,

además, para retardo $k = 0$, $C_{2x}(k)$ corresponde a la varianza de la señal.

En la Figura 2, se puede apreciar, que las estructuras, que representan el campo escalar definido por el cumulante de tercer orden $C_{3x}(k,l)$, tienen comportamientos visiblemente muy diferentes. Mientras que la imagen del cumulante de la señal de un paciente de control, mostrada en la Figura 2a está conformada por una estructura de puntos de máxima energía (color amarillo) distribuidos con alta periodicidad; la estructura, en el caso de la señal de un paciente epiléptico, Figura 2b, es una región de máxima energía, concentrada en el centro del rectángulo de la imagen.

Esta diferencia, en las estructuras de la imagen de $C_{3x}(k,l)$, las percibe la CNN Inception, entrenada como detector de epilepsia, como rasgo discriminador de la neuropatía en un EEG.

3.2. Prueba de linealidad y gaussianidad

Una prueba estadística, para comprobar la linealidad y gaussianidad de señales, es el algoritmo de Hinich [18]. El algoritmo se basa en detectar la condición de oblicuidad (asimetría) diferente de cero en la función de distribución: esta condición se mide con la estadística “skewness” y se fundamenta en, el hecho de, que, en un proceso gaussiano, los cumulantes de orden mayor a dos son

cero y, en consecuencia, también lo son el bispectro y la bicoherencia.

Entonces, existe la hipótesis nula de no gaussiano si se determina que el bispectro es distinto de cero; por otro lado, si además la bicoherencia, no es constante, se debe concluir que el proceso es no lineal. Swami *et al.* [8], construyeron una herramienta de software para uso académico, que denominaron HOSA, desarrollada con el software matemático Matlab, que, entre muchas otras más funciones, implementa el algoritmo de Hinich, con estimaciones consistentes y no sesgadas de la bicoherencia y el bispectro.

3.3. Red Neuronal Convolutiva Inception

La CNN Inception se basa en la aplicación del módulo Inception [9]. La característica clave del módulo Inception, utilizada en la implementación del modelo GoogLeNet (ganador del concurso ILSVRC 2014), se muestra en la Figura 3. El modelo GoogLeNet consta de 22 de estos módulos.

El principio básico detrás de la estructura del módulo Inception se inspira en el hecho, de que, a medida, que aumenta el número de capas de una CNN, así como su ancho, su precisión también aumenta. Sin embargo, la implantación de este principio, se refleja en un incremento creciente de los recursos computacionales, que, por supuesto, son limitados; además, crece proporcionalmente el número de parámetros a entrenar, lo que aumenta la tendencia a sobreajustes (degrada la capacidad de generalización) [9, 15].

El módulo Inception tiene como objetivo satisfacer los requisitos de aumentar las capas convolucionales, horizontalmente (ancho), en lugar de aumentar el tamaño de la red en profundidad, extrayendo características en cada capa a diferentes niveles de resolución (filtros de convolución).

Como puede observarse en las Figuras 3a y 3b, el tensor de entrada, al módulo Inception, es procesado por varias ramas convolucionales paralelas cuyas salidas luego se fusionan en un único tensor de salida. Para evitar problemas de alineación de imágenes de salida, de procesos intermedios, la implementación de la arquitectura Inception, está restringida a tamaños de filtro 1×1 , 3×3 y 5×5 . La salida de un módulo es

un solo tensor de salida, que es una combinación de los bancos de filtros de salida, concatenados y forma la entrada a la siguiente etapa. El módulo de versión de dimensiones reducida (Figura 3b) disminuye la salida del vector concatenado, al colocar en cascada al bloque “pooling” [9, 15], un filtro adicional 1×1 ; el efecto de esta variante, si bien aumenta, el tiempo de proceso con el nuevo filtro, se adiciona una función de activación extra “Relu” [9, 15], en el bloque convolutivo, con los beneficios implícitos, de agregar no linealidad.

En la Figura 4, se muestra la arquitectura completa de la implementación de GoogLeNet, los dos últimos bloques (a la derecha), identificados en la leyenda como: “Fully connected”, de color violeta, y “Softmax”, de color rojo, constituyen, lo que se conoce como etapa clasificadora, mientras que el resto, se le denomina etapa o base convolutiva. La base convolutiva es la responsable de la extracción de rasgos de la imagen; mientras, que la etapa clasificadora es un perceptrón multicapa [15], de dos capas.


4. Metodología

En la presente sección se describe la metodología, la cual abarca fundamentalmente dos aspectos: procesamiento del EEG y diseño del clasificador.

4.1. Procesamiento del EEG

El procesamiento del EEG se inicia con la obtención de la base de datos de EEG a estudiar, continúa con el procesamiento y selección del canal y finaliza con la generación del conjunto de imágenes de entrenamiento al clasificador. A continuación, se describe cada tarea:

1. Obtención de la base de datos a estudiar, esto es, acopio de EEG de pacientes diagnosticados epilépticos y EEG de pacientes neurológicamente sanos. Con esta tarea, se define una base de datos, de dos clases: EEG epilépticos y EEG de control.
2. Procesamiento y selección del canal: En la fase de procesamiento, a cada EEG, se le aplicó filtrado digital para eliminación y/o reducción de artefactos [2, 5], mediante



(a) versión básica

(b) versión con dimensiones reducidas

Figura 3: Diagrama de bloques del módulo Inception





Figura 4: Diagrama de bloques de GoogLeNet


el software EEGLAB [7]. El programa se configuró para filtrado pasa-bandas, entre 0,1 y 100 Hz (banda pasante de EEG [2]), con filtrado adicional de rechazo de ruido de línea de modo común de 60 Hz. Para la selección del canal, se adoptó como criterio, identificar el canal con máxima potencia; estrategia, que funcionó satisfactoriamente en investigaciones previas [11]. EEGLAB permitió obtener la respuesta espectral del EEG y la identificación visual del canal de máxima potencia, como puede observarse en las Figuras 5a y 5b.

3. Generación del conjunto de entrenamiento; la señal del canal seleccionado se segmenta en trozos solapados, que conserven los

atributos de no linealidad y no “gaussianidad” [18, 17]. Este proceso de segmentación con solapamiento, tiene el objetivo de aumentar el tamaño del conjunto de datos acopiado; aspecto clave, para evitar el riesgo de sobreajuste en el entrenamiento [9, 15]. A cada segmento, se le calculó el correspondiente cumulante de tercer orden, mediante HOSA, para generar las señales bidimensionales. Estas señales bidimensionales se guardaron como imágenes, recortadas a dimensiones compatibles con la CNN a usar, de modo de poder integrar el conjunto de datos de entrenamiento, validación y prueba. En el caso actual, la dimensión de cada imagen es 229×229 , que es el formato de imagen



(a) Paciente de control



(b) Paciente epiléptico reducidas

Figura 5: Respuesta espectral del EEG

compatible con la CNN Inception.

4.2. Diseño del clasificador

En esta investigación, se usó la arquitectura de CNN pre-entrenada: Inception. El modelo utilizado en la arquitectura es del formato “No Top”,

lo que significa, que del modelo preentrenado, solo se utilizó la estructura correspondiente a la base convolucional, mientras que, la etapa clasificadora se sustituyó por un perceptrón multicapa especializado en la base de datos de EEG. La técnica de adaptar una red pre-entrenada a

una base de datos, distinta a la usada para entrenarla originalmente, se conoce como aprendizaje por transferencia (“transfer learning” [15]). La CNN Inception mostró buen desempeño, evaluada con el conjunto de datos generado para los experimentos, y en consecuencia, fue la CNN seleccionada para la tarea de clasificador, del sistema.

La Figura 6, muestra la estructura de las cuatro últimas capas del clasificador implementado con Inception. La capa identificada como “avg_pool” es la capa de salida de la base convolucional, tiene un ancho de 2048 neuronas, y se convierte en la dimensión del tensor, que se conecta a la capa de entrada, de la etapa clasificadora final. Las capas a continuación, conforman el perceptrón multicapa (etapa clasificadora), con una capa “dropout” [15], para aumentar la capacidad de generalización del modelo; inmediatamente, una capa intermedia totalmente interconectada, también llamada densa, de 100 neuronas y otra capa densa final de dos neuronas (las dos clases: epiléptico y control). El total de parámetros entrenables es de 205.192, el total de parámetros del detector (base convolucional mas etapa clasificadora) es de 22.007.886, lo cual es una cifra modesta, comparada con otras arquitecturas pre-entrenadas [9].

5. Análisis y discusión de resultados

Siguiendo los pasos definidos en la metodología, la fase experimental produjo los siguientes resultados:

5.1. Procesamiento del EEG

1. Base de datos

La base de datos usada corresponde a los EEG de 10 pacientes correctamente diagnosticados epilépticos y 10 pacientes de control, provenientes del banco de datos del Laboratorio de Electrofisiología del Hospital San Juan de Dios de Mérida [19]. Para cada EEG se registraron 19 canales electroencefalográficos usando el método referencial (diferencias de potencial entre el sitio activo y un punto de referencia dado por ambos lóbulos auriculares cortocircuitados), la frecuencia de muestreo fue 256 Hz. Los registros fueron

realizados tanto para controles como pacientes en estado de vigilia con ojos cerrados durante aproximadamente cinco minutos.

2. Procesamiento y selección del canal

Para cada uno de los EEG de la base de datos, se aplicó filtrado digital pasabandas 0,1-100 Hz) y de línea (60 Hz); así como también, se eliminaron segmentos, que, a simple inspección visual, lucieron afectados por artefactos técnicos, tales como desplazamiento accidental de electrodos [2, 4]. En cada EEG, ya filtrado, se identificó el canal que exhibió mayor potencia, usando la respuesta espectral, mediante EEGLAB (Figuras 5a y 5b). En el caso de EEG de pacientes epilépticos, se detectó gran variabilidad en la identidad del canal de máxima potencia, mientras que, en el caso de pacientes de control, la identificación del canal, se concentró en los canales de la región occipital (15 al 19), lo que es consistente con la condición de relajación y ritmo cerebral alfa [2].

3. Generación de imágenes

Con 20 señales disponibles (10 canales epilépticos y 10 de control); para cada señal se cortaron segmentos de 128 muestras, solapados 50%, con inicio de segmento aleatorio; lo que permitió obtener 2000 segmentos diferentes por clase. A cada uno de los segmentos, se les realizó el siguiente procedimiento:

- Verificación de condición de no gaussianidad y no linealidad.
- Cálculo de cumulante de tercer orden $C_{3x}(k, l)$.
- Recorte a dimensiones 299×299 pixeles, para compatibilidad con Inception.

La base datos fue de 4000 imágenes de 299×299 pixeles (2000 imágenes por clase).

5.2. Entrenamiento del clasificador

La CNN Inception se entrenó con la base de datos disponible de 2000 imágenes de $[299 \times 299]$ por clase. La base de datos organizada como 80% de entrenamiento (1600 por clase) y 20% para validación (200 por clase) y prueba (200 por clase).

```

=====
avg_pool (GlobalAveragePooling2 (None, 2048))      0      mixed10[0][0]
-----
dropout_3 (Dropout) (None, 2048)      0      avg_pool[0][0]
-----
dense_4 (Dense) (None, 100)      204900  dropout_3[0][0]
-----
dense_5 (Dense) (None, 2)      202     dense_4[0][0]
=====
Total params: 22,007,886
Trainable params: 205,102
Non-trainable params: 21,802,784
=====

```

Figura 6: Capas finales del clasificador usando Inception

El detector exhibió una exactitud de 96,5 % y 94,5 % para entrenamiento y prueba respectivamente, el número de épocas empleado fue de 20, con una duración de 90 segundos promedio por época, lo que representó un lapso total de tiempo entrenamiento, de aproximadamente 35 minutos. Las Tablas 1 y 2, resumen los resultados experimentales.

Tabla 1: Base de datos de clasificador

Clase	Imágenes por clase	Imágenes entrenamiento	Imágenes validación /prueba
Epiléptico	2000	1600	400
Control	2000	1600	400
Total, clases: 2	Total, clases: 2	entrenamiento: 3200	validación / prueba: 800

Tabla 2: Parámetros de entrenamiento de clasificador a CNN Inception

Modelo	Épocas	Exactitud de entrenamiento %	Exactitud de prueba %
EEG_Incep_01.h	20	96.5	94.5

5.3. Análisis de resultados

La aplicación del algoritmo de Hinich, permitió verificar la naturaleza no lineal y no gaussiana del EEG, tanto para pacientes epilépticos como de control.

La medición de la máxima potencia en la respuesta espectral, de los canales que conforman

el registro del EEG, indicaron que, en los pacientes de control, la mayor actividad cerebral se concentra en la región occipital, lo cual es consistente con el estado de relajación, en el que se encontraban al momento de la captación del EEG, y asociado al estado alfa de los ritmos cerebrales. Por otro lado, la alta variabilidad en la identificación del canal de máxima potencia, en el caso de EEG epiléptico, puede estar correlacionado con el foco epiléptico [2] del paciente, lo que sugiere un tema de investigación a explorar.

Las representaciones bidimensionales de los cumulantes de tercer orden, permitieron discriminar, en forma efectiva, los rasgos subyacentes de condición epiléptica, respecto a la de control, y en consecuencia lograr una alta precisión, en la detección de la neuropatía. La selección de la red Inception fue acertada, ya que tuvo un excelente desempeño en la tarea de clasificación.

6. Conclusiones

En este artículo se presentó el diseño y evaluación de un sistema detector de neuropatías basado en aprendizaje profundo y técnicas de análisis de orden superior.

La neuropatía, usada como clase a predecir, fue epilepsia, por ser una de las neuropatías más comunes y con alta degradación, en la calidad de vida, del enfermo.

Se verificó el comportamiento altamente no lineal y no gaussiano de las series de tiempo derivadas de registros electroencefalográficos y en consecuencia la acertada selección del uso

de métricas estadísticas de orden superior, para entrenar el sistema detector.

El desempeño del detector fue muy satisfactorio, alcanzando una exactitud de 94,5 % en el conjunto de prueba. La selección de la red Inception, en la implementación del clasificador, así, como el uso de la técnica de aprendizaje por transferencia, en su entrenamiento, mostró una alta efectividad.

Los resultados de este estudio sugieren la conveniencia de desarrollar este tipo de herramientas computacionales, de alta precisión, para el diagnóstico de otras neuropatologías.

7. Referencias

- [1] U. K. Patel, A. Anwar, S. Saleem, P. Malik, B. Rasul, K. Patel, R. Yao, A. Seshadri, M. Yousufuddin, and K. Arumathurai, "Artificial intelligence as an emerging technology in the current care of neurological disorders," *Journal of Neurology*, Aug. 2019.
- [2] L. Sörnmo and P. Laguna, *Bioelectrical Signals Processing in Cardiac and Neurological Applications*. Amsterdam: Elsevier Academic Press, 2005.
- [3] U. Raghavendra, U. Acharya, and H. Adeli, "Artificial Intelligence Techniques for Automated Diagnosis of Neurological Disorders," *Europea Neurology*, vol. 82, pp. 41–64, 2019.
- [4] C. Seijas, A. Caralli, and S. Villazana, "Estimation of Action Potential of the Cellular Membrane using Support Vectors Machines," in *Proceedings of the 28th IEEE EMBS Annual International Conference*, 2006, pp. 4200–4204.
- [5] M. Teplan, "Fundamentals of EEG Measurement," *Measurement science review*, vol. 2, pp. 1–11, 2002.
- [6] S. Smith, "EEG in the Diagnosis, Classification, and Management of Patients with Epilepsy," *Journal of Neurology, Neurosurgery & Psychiatry*, vol. 76, no. Supplement 2: ii2-ii7, 2005.
- [7] A. Delorme and S. Makeig, "EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis," *Journal of Neuroscience Methods*, vol. 132, pp. 9–12, 2004.
- [8] A. Swami, J. Mendel, and C. Nikias, *Higher-Order Spectral Analysis Toolbox: User's Guide*. The MathWorks Inc., 2007.
- [9] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, v. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2008, pp. 1–9.
- [10] N. Mahmoodian, J. Haddadnia, A. Illanes, A. Boese, and M. Friebe, "Seizure prediction with cross-higher-order spectral analysis of EEG signals," *Signal, Image and Video Processing*, vol. 14, pp. 821–828, 2020.
- [11] C. Seijas, A. Caralli, and S. Villazana, "Neuropathology Classifier Based on Higher Order Spectra," *Journal of Computer and Communications*, vol. 1, no. 4, pp. 36–40, 2013.
- [12] A. Craik, y. He, and J. Contreras-Vidal, "Deep learning for electroencephalogram (EEG) classification tasks: a review," *Journal Neural Engineering*, vol. 16, no. 3, pp. 1–28, 2019.
- [13] M. Golmohammadi, A. Hossein, H. Nejad, S. Lopez de Diego, I. Obeid, and J. Picon, "Automatic Analysis of EEGs Using Big Data and Hybrid Deep Learning Architectures," *Frontiers in human neuroscience*, 2019.
- [14] L. Gemein, R. Schirrmeyer, P. Chrabaszcz, D. Wilson, J. Boedecker, A. Schulze-Bonhage, F. Hutter, and T. Ball, "Machine-learning-based diagnostics of EEG pathology," *Neuroimage*, vol. 220, p. 117021, 2020.
- [15] F. Chollet, *Deep Learning with Python*. New York, USA.: Manning Publications Co., 2018.
- [16] C. Wen-Yean, M. Murugappan, M. Iqbal, W. Khai-runizam, B. Siao-Zheng, A. Joseph, and Z. Ibrahim, "A Study of Non-Gaussian Properties in Emotional EEG in Stroke Using Higher-Order Statistics," in *Advances in Electrical and Computer Technologies. Select Proceedings of ICAECT 2019*, T. Sengodan, M. Murugappan, and S. Misra, Eds., vol. 672. Springer, 2020, pp. 635–645.
- [17] P. Cauchy, S. Jena, S. Nadar, and N. Pradhan, "Higher-Order Spectrum in Understanding Nonlinearity in EEG Rhythms," *Hindawi Publishing Corporation Computational and Mathematical Methods in Medicine*, vol. 2012, no. ID 206857, 2012.
- [18] M. Hinich, "Testing for Gaussianity and Linearity of a Stationary Time Series," *Journal of Time Series Analysis*, vol. 3, no. 3, 1982.
- [19] P. Guillén, "Procesamiento Digital de EEG," Tesis doctoral, Universidad de los Andes, Mérida, Venezuela., 2005.