



**UNIVERSIDAD PEDAGÓGICA
NACIONAL**


Educadora de educadores

MÉTODOS PARA LA DETECCIÓN AUTOMÁTICA
DE LA EPILEPSIA DESARROLLADOS EN LOS ÚLTIMOS 20 AÑOS

DOCUMENTO PRESENTADO PARA OPTAR AL TÍTULO DE LICENCIADO EN DISEÑO
TECNOLÓGICO POR:

JULIAN MAURICIO MORALES ZABALA


UNIVERSIDAD PEDAGÓGICA NACIONAL FACULTAD DE CIENCIA Y TECNOLOGÍA
DEPARTAMENTO DE TECNOLOGÍA LICENCIATURA EN DISEÑO TECNOLÓGICO
BOGOTÁ D.C. 2019

 UNIVERSIDAD PEDAGÓGICA NACIONAL <small>Revisión de la Educación</small>	FORMATO
	RESUMEN ANALÍTICO EN EDUCACIÓN - RAE
Código: FOR020GIB	Versión: 01
Fecha de Aprobación: 10-10-2012	Página 2 de 6

1. Información General	
Tipo de documento	Trabajo de grado.
Acceso al documento	Universidad Pedagógica Nacional. Biblioteca Central.
Título del documento	Métodos Para La Detección Automática De La Epilepsia Desarrollados En Los Últimos 20 Años.
Autor(es)	Morales Zabala, Julián Mauricio.
Director	Luis Carlos Sarmiento.
Publicación	Bogotá. Universidad Pedagógica Nacional, 2019. 34 p.
Unidad Patrocinante	Universidad Pedagógica Nacional.
Palabras Claves	ALGORITMO, DETECCIÓN, EPILEPSIA, ELECTROENCEFALOGRAMA.


2. Descripción
<p>Esta revisión bibliográfica tiene el objetivo de conocer la evidencia científica disponible sobre los métodos en la detección automática de los eventos epilépticos. La búsqueda bibliográfica se ha llevado a cabo en las bases de datos, de los últimos 20 años. De artículos correspondientes a estudios experimentales originales sobre tratamientos epilépticos, específicamente sobre la detección automática de eventos epilépticos, se expone una serie de métodos algorítmicos que se han venido incorporando entorno a la detección automática de eventos epilépticos en las lecturas de electroencefalogramas (EEG). Esta revisión describe brevemente primero los factores clínicos no detallados: síntomas, causas, diagnóstico. Y segundo revisa hallazgos de los estudios enfocados en las lecturas automáticas EEG para la detección de crisis epiléptica.</p>

3. Fuentes
<ul style="list-style-type: none"> • R. G. Andrzejak, G. Widman, K. Lehnertz, C. Rieke, P. David, and C. E. Elger. (2001). "The epileptic process as nonlinear deterministic dynamics in a stochastic environment: An evaluation on mesial temporal lobe epilepsy," <i>Epilepsy Res.</i>, vol.44, pp. 129–140. http://epileptologiebonn.de/cms/front_content.php?idcat=193&lang=3&changelang=3 • T. Oates R.T.G, Merry (1993) Electroencephalogram epileptiform abnormalities in candidates for aircrew training R.P. Gregory. <i>Electroencephalogr Clin. Neurophysiol.</i> 1993; 86:75-77. • T. Oates R.T.G, Merry (1993). Electroencephalogram epileptiform abnormalities in candidates for aircrew training R.P. Gregory. <i>Electroencephalogr Clin. Neurophysiol.</i> 1993; 86:75-77. • Zivin L, Ajmone-Marsan C. (1968). Incidence and prognostic significance of "epileptiform" activity in the EEG of nonepileptic subjects. <i>Brain</i> 1968; 91:751-778. • Kellaway Peter. (2003). <i>Orderly Approach to Visual Analysis: Elements of the Normal EEG and</i>

 UNIVERSIDAD PEDAGÓGICA NACIONAL <small>Enseñanza de la Pedagogía</small>	FORMATO
	RESUMEN ANALÍTICO EN EDUCACIÓN - RAE
Código: FOR020GIB	Versión: 01
Fecha de Aprobación: 10-10-2012	Página 3 de 6

Their Characteristics in Children and Adults. In: Ebersole JS, Pedley TA, Eds. Current Practice of Clinical Electroencephalography, 3rd edition, 2003:100-159.

- J. Ma. Mercade Cerda, Sancho Rieger. (2012). Guías diagnósticas y terapéuticas de la Sociedad Española de Neurología 2012. 1. Guía oficial de práctica clínica en epilepsia © 2012, Sociedad Española de Neurología ISBN obra completa: 978-84-7989-750-5.
- Robert S. Fisher, J. Helen Cross, Jacqueline A. French, Norimichi Higurashi, Edouard Hirsch, Floor E. Jansen. (2017). Clasificación operacional de los tipos de crisis por la Liga Internacional contra la Epilepsia: Documento - Posición de la Comisión para Clasificación y Terminología de la ILAE. <https://www.ilae.org/files/ilaeGuideline/Spanish-Traduccion-Fisher-Seizure-types.pdf>.
- Luis Enrique Morillo Zarate, (2005) "Análisis visual del electroencefalograma" Guía Neurológica 7 - Neuro Electro Diagnóstico. En: Colombia ISBN: 0 ed.: Asociación Colombiana de Neurología, v.7, p.143 - 163 7. <https://www.acnweb.org/guia/g7cap17.pdf>.
- Eslava J, Espinosa E, Izquierdo A, Medina-Malo C, Nariño D, Carreño O. (2006). Consenso Colombiano de Epilepsia. Acta neurológica colombiana vol. 22 no. 4 suplemento (1:1) † 2006 issn 0120-8748 publicación oficial de la asociación acta neurológica colombiana 2006; 22:365-404 colombiana de neurología. https://www.acnweb.org/acta/2006_22_4s_in.pdf.
- Huang LT, Cilio MR, Silveira DC, (1999). Long term effects of neonatal seizures: a behavioral electrophysiological and histological study. Dev Brain Res 1999; 118: 99-107 https://scielo.conicyt.cl/scielo.php?script=sci_nlinks&ref=7506376&pid=S0370-4106200100030000200021&lng=es.
- Department of Neurology, University of Erlangen-Nuremberg Schwabachanlage 6, D-91054 Erlangen, Germany Ruediger, Hopfengaertner, Hermann.Stefan@neuro.med.uni-erlangen.
- He Sheng Liu, Tong Zhang, and Fu Sheng Yang. (2002) A Multistage, Multimethod Approach for Automatic Detection and Classification of Epileptiform EEG Transactions On Biomedical Engineering, Vol. 49, No. 12, December 2002.
- Nurettin Acir, İbrahim Öztura, Mehmet Kuntalp, Baris Baklan, and Cüneyt Güzelis (2005) Automatic Detection of Epileptiform Events in EEG by a Three-Stage Procedure Based on Artificial Neural Networks EEG Transactions On Biomedical Engineering, Vol. 52, No. 1, January 2005.
- Themis P. Exarchos, Alexandros T. Tzallas, Dimitrios I. Fotiadis, Member, IEEE, Spiros Konitsiotis, and Sotirios Giannopoulos. (2006) Transactions On Information Technology In Biomedicine, Vol. 10, No. 3, July 2006 451 EEG Transient Event Detection And Classification Using Association Rules.
- Samanwoy Ghosh-Dastidar, Hojjat Adeli, (September 2007) and Nahid Dadmehr leee Transactions On Biomedical Engineering, Vol. 54, No. 91545 Mixed-Band Wavelet-Chaos-Neural Network Methodology for Epilepsy and Epileptic Seizure Detection.
- Samanwoy Ghosh-Dastidar, Hojjat Adeli, and Nahid Dadmehr.(2008).Transactions On Biomedical Engineering, Vol. 55, No. 2, February 2008 Principal Component Analysis-Enhanced Cosine Radial Basis Function Neural Network for Robust Epilepsy and Seizure Detection.

 UNIVERSIDAD PEDAGÓGICA NACIONAL <small>Encuentro de Pedagogías</small>	FORMATO
	RESUMEN ANALÍTICO EN EDUCACIÓN - RAE
Código: FOR020GIB	Versión: 01
Fecha de Aprobación: 10-10-2012	Página 4 de 6

- Petros Xanthopoulos, Steffen Rebennack, Chang-Chia Liu, Jicong Zhang, Gregory L. Holmes, Basim M. Uthman, and Panos M. Pardalos.(2010). A novel wavelet based algorithm for spike and wave detection in absence epilepsy.
- Ye Yuan. (2010). Detection of Epileptic Seizure Based on EEG Signals. Department of Electronics Engineering Shantou University Shantou, China.
- Sourya Bhattacharyya, Arunava Biswas, Jayanta Mukherjee, Arun Kumar Majumdar, Bandana Majumdar, Suchandra Mukherjee, and Arun Kumar Singh (2011). Feature Selection for Automatic Burst Detection in Neonatal Electroencephalogram. Journal On Emerging And Selected Topics In Circuits And Systems, Vol. 1, No.4.
- Azian Azamimi Abdullah, Saufiah Abdul Rahim and Adira Ibrahim. (2012). Development of EEG-based Epileptic Detection using Artificial Neural Network. 2012 International Conference on Biomedical Engineering (ICoBE),27-28 February 2012, Penang.
- S. M. Shafiul Alam and M. I. H. Bhuiyan (2013) Journal Of Biomedical And Health Informatics, Vol. 17, No. 2, Detection of Seizure and Epilepsy Using Higher Order Statistics in the EMD Domain.
- C.F. Reyes, T. J. Contreras, B.Tovar, and L.I.Garay. (2013). Detection of Absence Epileptic Seizures Using Support Vector Machine. 2013 10th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE) Mexico City, Mexico.
- Ning Wang, and Michael R. Lyu, Fellow. (2015) Journal Of Biomedical And Health Informatics, Vol. 19, No. 5, Extracting And Selecting Distinctive Eeg Features for Efficient Epileptic Seizure Prediction.
- Musa Peker, Baha Sen, and Dursun Denle (2016) Journal Of Biomedical And Health Informatics, Vol. 20, No. 1, A Novel Method for Automated Diagnosis of Epilepsy Using Complex-Valued Classifiers.
- Ashwani Kumar Tiwari, Ram Bilas Pachori, Vivek Kanhangad, and Bijaya Ketan Panigrahi. (2017). Journal Of Biomedical And Health Informatics, Vol. 21, No. 4, Automated Diagnosis of Epilepsy Using Key-Point-Based Local Binary Pattern of EEG Signals.
- Rohit Bose, Sawon Pratiher, Soumya Chatterjee (2018) Detection of epileptic seizure employing a novel set of features extracted from multifractal spectrum of electroencephalogram signals, Institute for Neurotechnology, National University of Singapore.
- Kashif Ahmad Khan, Muhammed Shanir P. P., Yusuf Uzzaman Khan, Omar Farooq. (2019). A hybrid Local Binary Pattern and Wavelets based approach for EEG classification for diagnosing epilepsy.
- Shanen Chen, Xi Zhang, Lili Chen, And Zhixian Yang (2019) Automatic Diagnosis of Epileptic Seizure in Electroencephalography Signals Using Nonlinear Dynamics Features Department of Industrial Engineering and Management, Peking University, Beijing 100871, China, Department of Pediatrics, Peking University First Hospital, Beijing 100034.



4. Contenidos

El documento se estructura en una composición de artículo de revisión descriptiva. En la parte preliminar se presenta un reconocimiento conceptual a cerca de la Epilepsia sus factores clínicos no detallados. marco teórico con el propósito de mencionar las características clínicas y síndromes más comunes, basado en la Norma Ilae (2001), y separados de acuerdo a la edad cronológica del paciente. Además de algunos aspectos electroencefalográficos encontrados en esas edades. En los aspectos preliminares se presenta un recorrido relativo la epilepsia, como son: principios de la actividad neuronal, diagnóstico de actividad encefalográfica pileptogénica, procesamiento de la señal electroencefalográfica y análisis espectral.

Posteriormente se presenta la descripción de los artículos encontrados separados por épocas de quinquenios sobre métodos de detección automática de la epilepsia desarrollados en los últimos 20 años y la metodología usada en cada uno de los artículos, por último, análisis de las etapas y conclusiones finales del trabajo.

5. Metodología


Para el artículo se utilizaron búsquedas en base de datos con palabras clave como epilepsy, detección and epilepsy, detection epilepsy + EEG. Encontrándose (65.926-19.473-5.672) referencias respectivamente. Se discriminaron artículos para llegar al total de 101 artículos de los cuales fueron confirmados 17 para este documento; con el fin de encontrar soluciones para la detección automática de la epilepsia con estudios de métodos algorítmicos de extracción de características y métodos clasificadores en las señales EEG de los últimos 20 años.

Consecutivamente los artículos destacados se dividieron en etapas de artículos por años así: Primera etapa del año 2000-2005 segunda etapa 2006-2010 tercera etapa 2011-2015 cuarta etapa 2016-2019. Se describen metodologías usadas en cada uno de los artículos se hace mención de los algoritmos utilizados junto a los métodos y el método evaluativo de los artículos.

6. Conclusiones

las dificultades en el manejo de la epilepsia resistente al tratamiento pueden mejorarse por la capacidad de detectar convulsiones. Estos sistemas de detección y predicción tempranos podrían abortar las convulsiones a través de terapias dirigidas, los sistemas de detección y predicción aquí descritos están disponibles actualmente para las crisis epilépticas. Se explora además la posible aplicación de dichos sistemas en la monitorización ambulatoria y los modelos de circuito cerrado para la atención individual de pacientes. Un sistema de detección de ataques debe poder determinar la presencia o ausencia de ataques continuos.

Los métodos automatizados de análisis EEG están surgiendo del concepto de que la dinámica cerebral normal, que implica una sincronización limitada y transitoria de la actividad neuronal desorganizada,

 UNIVERSIDAD PEDAGÓGICA NACIONAL <i>Resistencia al cambio</i>	FORMATO	
	RESUMEN ANALÍTICO EN EDUCACIÓN - RAE	
Código: FOR020GIB	Versión: 01	
Fecha de Aprobación: 10-10-2012	Página 6 de 6	

evoluciona a un estado persistente y altamente sincronizado que incorpora grandes regiones del cerebro durante las crisis epilépticas, los avances en los métodos de aplicación algorítmica han avanzado aumentando la confiabilidad en la detección de crisis y la reducción de tiempo en el diagnóstico de las patologías epileptiformes mediante métodos no invasivos.

Elaborado por:	Morales Zabala Julián Mauricio
Revisado por:	Luis Carlos Sarmiento

Fecha de elaboración del Resumen:	19	9	2019
--	----	---	------

Métodos Para La Detección Automática De La Epilepsia Desarrollados en Los Últimos 20 Años

Julián Mauricio Morales Zabala

Universidad Pedagógica Nacional, Departamento De Ciencia y Tecnología,
Epilepsia Bogotá, Colombia

IN F. DEL ARTICULO

Palabras Clave:

Algoritmo
detección
Epilepsia
Electroencefalograma

RESUMEN

Esta revisión bibliográfica tiene el objetivo de conocer la evidencia científica disponible sobre los métodos en la detección automática de los eventos epilépticos. La búsqueda bibliográfica se ha llevado a cabo en las bases de datos, de los últimos 20 años. De artículos correspondientes a estudios experimentales originales sobre tratamientos epilépticos, específicamente sobre la detección automática de eventos epilépticos, se expone una serie de métodos algorítmicos que se han venido incorporando entorno a la detección automática de eventos epilépticos en las lecturas de electroencefalogramas (EEG). Esta revisión describe brevemente primero los factores clínicos no detallados: síntomas, causas, diagnóstico. Y segundo revisa hallazgos de los estudios enfocados en las lecturas automáticas EEG para la detección de crisis epiléptica.

KEYWORDS

Algorithm
detection
Epilepsy
Electroencephalogram

ABSTRACT

This bibliographic review has the objective of knowing the available scientific evidence on the methods in the automatic detection of epileptic events. The bibliographic search has been carried out in the databases of the last 20 years. From articles corresponding to original experimental studies on epileptic treatments, specifically on the automatic detection of epileptic events, a series of algorithmic methods that have been incorporated around the automatic detection of epileptic events in electroencephalogram (EEG) readings are presented. This review briefly describes first the non-detailed clinical factors: symptoms, causes, diagnosis. And second it reviews the findings of studies focused on automatic EEG readings for the detection of epileptic seizures.

EPILEPSIA

La epilepsia es un síntoma complejo provocado por una amplia gama de procesos patológicos del cerebro. Se caracteriza por la descarga ocasional (paroxística), excesiva y desordenada de neuronas. Sin embargo para una comprensión aproximada etiológica con miras a abordar el tema enfocaremos Según la revisión para la clasificación de las crisis epilépticas la revisión de 1981 de la *Clinical and electroencephalographic classification of epileptic seizures of the International League Against Epilepsy* y 2001 de la *International League Against Epilepsy (ILAE)* dividiremos la clasificación en dos, las crisis bajo las modalidades de crisis primaria: que puede ser generalizada o focal y crisis secundaria: focales que se pueden generalizar y Nos referiremos a periodos durante la crisis (Ictal o incautación), posterior a la crisis (postictal) periodos entre crisis (interictal o de no incautación). Existe además un porcentaje de crisis de difícil clasificación generalmente asociadas a cuadro de base u otras enfermedades cerebrales progresivas y otro en el que la causa etiológica es idiopática o desconocida. La importancia de la correcta clasificación de la epilepsia como un síndrome epiléptico determinado, permite establecer una adecuada medicación y tratamiento, así como reconocimiento del tipo de evento epiléptico síndrome que se esté presentando.

Para los métodos de detección automática es conveniente remitirnos a los grupos de síndromes epilépticos según su manifestación clínica y edad ya que la etiología sea desconocida o no constituyen en el diagnóstico clínico la identificación de descargas paroxísticas epileptiformes frecuentes en cualquier edad y el tema se configura en el diagnóstico clínico y detección de las crisis Localizadas en los EEG.

MARCO TEORICO

Síndromes Y Diagnostico Epilépticos De Acuerdo A La Edad

El propósito de este apartado es mencionar algunas de las características clínicas y síndromes más comunes de acuerdo a la edad en que aparece la epilepsia, además de advertir que existen múltiples clasificaciones y opiniones médicas al respecto que se encuentran en la literatura y pueden o no ubicarse dentro del rango de edades estrictamente. La ILAE 2001, le asigna los nombres a la epilepsia parcial con nuevas terminologías de “epilepsia focal sintomática” o “epilepsia focal probablemente sintomática” esto con el fin de entender literaturas que no adoptan la terminología propuesta antes del año 2001.

Recién nacido a 44 semanas de gestación

Las convulsiones neonatales resultan muy importantes, el diagnóstico etiológico, así como el tratamiento precoz y su monitoreo. También es fundamental el análisis que aporta el EEG interictal, particularmente el patrón de fondo. Cuando este es normal, las secuelas neurológicas se darán entre el 8 y 10% de los niños. Si la anomalía es severa, sobre el 90% tendrá secuelas definitivas. En relación a la etiología, la encefalopatía isquémica grado II y III producen un 50% de secuelas, la hemorragia intracraneal grado IV, un 90%, y las meningitis bacterianas, un 50%. En síntesis, las convulsiones neonatales tienen un 16% de mortalidad, particularmente las formas severas: la epilepsia mioclónica precoz, los errores innatos del metabolismo, las malformaciones del SNC, la encefalopatía epiléptica de Otahara. Según (Troncoso a 2001) estudios recientes, el 35% deja secuelas neurológicas en el largo plazo. También debe señalarse que las formas benignas, como las convulsiones benignas idiopáticas (o convulsiones del quinto día) y las convulsiones familiares benignas (herencia autosómica dominante) tienen mejor pronóstico los trastornos pre y perinatales más comunes son hipoxia-isquemia, hipoglicemia, hipocalcemia, alteraciones del sodio y otros trastornos hidroelectrolíticos, infecciones, malformaciones del sistema nervioso, errores innatos del metabolismo, intoxicación o síndromes de abstinencia. Un porcentaje importante de los pacientes con este tipo de crisis neonatales evolucionarán a epilepsias sintomáticas

Hallazgos Electroencefalográficos recién nacidos.

son de difícil diagnóstico en algunos casos como en las crisis neonatales focales benignas de la infancia la lectura EEG puede ser interictal normal ya que podrían o no generalizarse, en su orden podría diagnosticarse: sin compromiso del estado neurológico (neonatales benignas) y con compromiso del estado neurológico (Encefalopatías perinatales) para crisis neonatales benignas no familiares como en el caso de la crisis del quinto día con neonatos a término, el patrón descrito (theta Agudo dominante) suele asociarse, aunque a la enfermedad y junto con la apnea y la actividad clónica suelen desaparecer en unos pocos días. Sin embargo, el patrón (*theta pointu alternant*) no es específico de las crisis benignas puede presentarse en el contexto de varias encefalopatías neonatales. La hipsarritmia comienza en un 75% en menores de seis meses y en un 95% en menores de un año la incidencia de enfermedades como infecciones intrauterinas, trastornos metabólicos, esclerosis tuberculosa, encefalopatía hipoxia perinatal y otro ejemplo fig. (1).





Fig.1 paroxismo de supresión descargas polipunta-onda con periodos de supresión. (Tomado de manual de epilepsia 4ta edición Thomas R. Brown).

Se han descrito múltiples variaciones de hipsarritmia con brotes generalizados de actividad theta rítmica alfa y brotes de onda aguda-onda lenta, y con descargas focales persistentes.



Descarga epileptiforme focal fig. (2).




Fig. 2. Descarga pseudo-delta en un neonato con crisis. El inicio de la crisis electrográfica tuvo lugar en la flecha. Advértase el cambio de morfología (*) a medida que avanza la crisis (Tomado de manual de epilepsia 4ta edición Thomas R. Brown)

Infante O Lactante de 44 semanas a 2 años

En esta etapa se presentan tipos de crisis de orden etiológico como: crisis febriles, Neuroinfección, epilepsias idiopáticas, secuelas encefalopatías pre y perinatales, de orden metabólico - hidroelectrico, malformaciones congénitas, epilepsias idiopáticas - criptogenicas. Las crisis que se pueden presentar se asocian a las de orden febril prolongándose hasta la niñez, se debe recordar por otra parte que se toma como una condición benigna en la medida que pueda estar relacionada con otras enfermedades que desaparecen tan pronto se atiende la enfermedad descartando una condición aguda como la meningitis en su orden pueden ser sin y con alteración del desarrollo:

(Epilepsia atónica mioclónica benigna, trastornos paroxísticos no epilépticos (TPE) benignos, epilepsia con crisis mioclónica) y (encefalopatías mioclónicas tempranas, epilepsia con crisis atónico-mioclónicas, síndrome de Ohtahara, epilepsia mioclónica severa de la infancia, Síndrome de West.

Hallazgos Electroencefalográficos:

En este caso la hipsarritmia es más habitual en los patrones EEG se presenta una desorganización que consiste en ondas lentas de voltaje muy elevado, aleatorias, con puntas y ondas focales fig. (3).

fig3. Ondas y puntas agudas multifocales. ECG. Electrocardiograma. (Tomado de manual de epilepsia 4ta edición Thomas R. Brown).

El patrón EEG ictal más característico de los espasmos consiste en una onda positiva sobre la región central del vértex; también puede observarse actividad rápida (14 Hz a 16 Hz) de bajo voltaje o un aplanamiento difuso conocido como *actividad decremental*.

Algunos pacientes con espasmos pueden no presentar hipsarritmia al aparecer el trastorno, mientras que otros pueden mostrar registros EEG lentos con actividad epileptiforme infrecuente y evolucionar posteriormente hacia patrones hipsarrítmicos. Puede ser necesario realizar

registros EEG seriados para demostrar la presencia de hipsarritmia. (Thomas R.2008)

Niñez de 2 a 10 años de edad

Las personas afectadas en este caso presentan etiologías asociadas como son: Epilepsias idiopáticas, crisis febriles, Neuro infección, trauma, evento cerebro vascular, intoxicaciones, neoplastias, secuelas de encefalopatías pre y perinatales, degenerativas, malformaciones con tasa de mortalidad neonatal (TMN). Las crisis que puede presentar son:(Sin alteración en el desarrollo crisis focales, epilepsia centrotemporal benigna, epilepsia con paroxismos occipitales, epilepsia extrahipocampal entre otras epilepsias focales benignas; crisis generalizadas con ausencia: epilepsia con ausencia, epilepsia mioclónicas con ausencia, crisis con mioclonías; con alteración del desarrollo psicomotor crisis focales: epilepsias con puntas y ondas continuas durante el sueño de ondas lentas, epilepsias mesial temporal, síndrome de Landau-Kleffner, encefalitis de Rasmussen, epilepsia Extra-hipocampal, mioclónicas focales con crisis generalizadas como: la enfermedad de cuerpos de Lafora, ataxia mioclónica progresiva, enfermedad de Unverricht-Lundborg; entre las crisis generalizadas encontramos: epilepsia con puntas y ondas continuas durante el sueño de ondas lentas, epilepsia con ausencia mioclónica, epilepsia con crisis astatomioclonicas, síndrome de Landau-Kleffner, síndrome de Lennox-Gastaut (SLG) (ILAE 2001 Medina Malo 2014).

Hallazgos electroencefalográficos

epilepsia benigna de la niñez con puntas centrotemporales (EBNPC) este es un síndrome importante diferenciado en la niñez se presenta la región roldanica más específicamente en la cisura roldanica la evaluación y diagnostico son diferenciales de las otras crisis focales generalmente autosómica dominante ya que el 50% de los pacientes presenta parientes cercanos suele ser benigna y a menudo se presentan ictales nocturnas tónico-clónicas en cara y manos con salivación excesiva (sialorrea) una sensación somatosensorial (AURA). En SLG es la descarga de punta-onda lenta superpuesta sobre un fondo lento y alterado. La incidencia del SLG se ha calculado en 0,3 por cada 1.000 nacidos vivos.

Los complejos de punta-onda lenta o de onda aguda-onda lenta consisten en descargas generalizadas con una frecuencia de 1,5 a 2,5 Hz fig. (4) Es común que el sueño aumente la frecuencia de las descargas; en cambio, es raro que la hiperventilación y la estimulación fótica activen la actividad paroxística




Fig. (4) (tomado de manual de epilepsia 4ta edición Thomas R. Brown)

La manifestación EEG típica de las crisis tónicas es la aparición de descargas de ritmos rápidos a frecuencias entre 10 Hz y 20 Hz a ritmo rápido con una amplitud progresivamente creciente, a las cuales siguen en ocasiones unas pocas ondas lentas o puntas (Carlos Malo 2014).

“Para los pacientes adolescentes adultos y jóvenes es necesario realizar una clasificación etiológica común es así que encontramos en las tres etapas con fenotipos variables: (trauma, -neoplasias, de orden toxicometabólicas, neuro infección, evento cerebrovascular, epilepsia idiopática Malformaciones TMN” (Carlos malo 2014).

ADOLESCENTES 12 A 18

Crisis relacionadas: (sin alteración neurológica, crisis focales: epilepsia del lóbulo temporal mesial, epilepsia extrahipocampal; crisis generalizadas: epilepsia mioclónica juvenil, epilepsia de ausencia juvenil, epilepsia de gran mal del despertar) ;(con alteración neurológica, crisis focales: epilepsia temporal mesial, epilepsia extrahipocampal; crisis mioclónicas pueden ser focales o generalizadas como la enfermedad de cuerpos de lafora, ataxia mioclónica progresiva, enfermedad de Unverricht-Lundborg y generalizada: síndrome de Lennox-Gastaut. Las idiopáticas focales mencionadas en el grupo de la niñez pueden iniciar también en esta época. Otro grupo a considerar en esta edad son las epilepsias reflejas especialmente las fotosensibles. Se presentan las encefalopatías mioclónicas progresivas (EMP).

Hallazgos electroencefalográficos

En las EPM típicamente, la actividad alfa se ralentiza y acaba siendo sustituida por frecuencias en el rango theta y delta. La actividad epileptiforme consiste en paroxismos bilaterales y sincrónicos de puntas, polipuntas, o complejos punta-onda o polipunta-onda.

Cuando hay puntas focales, su localización más frecuente es la región occipital.

En situación de vigilia, la mioclonía puede asociarse, o no, a actividad de punta ó punta-onda. Durante el sueño puede producirse una disminución de las descargas de punta-onda.

ADULTEZ

Crisis de inicio de la adultez encontramos: (sin déficit neurológico, crisis focales: epilepsia temporal mesial, epilepsia extrahipocampal; con déficit neurológico, crisis focales: epilepsia temporal mesial, epilepsia extrahipocampal.

Crisis Con Factores Precipitantes No Epilépticos

Convulsiones febriles, crisis por ingesta o supresión de alcohol, inducidas por droga o fármacos, epilepsias reflejas simples, epilepsia fotosensible, por estímulos propioceptivos, somatosensoriales, asociadas a eclampsia.

GENERACION DE LA ACTIVIDAD NEURONAL

Las neuronas están formadas por bicapas lipídicas con proteínas que cruzan la membrana y forman canales iónicos. Las neuronas tienen un potencial de reposo que representa la diferencia de amplitud entre el interior y el exterior de la célula. Esta diferencia de potencial existe debido a la separación de las cargas positivas y negativas a ambos lados de la membrana celular.

En el espacio extracelular situado junto a la membrana predominan los iones Na^+ y Cl^- , mientras que en el espacio intracelular encontramos K^+ , proteínas y ácidos orgánicos. Las membranas son permeables al Na^+ , Cl^- y K^+ , pero no lo son a los iones orgánicos grandes y las proteínas. Dado que las bicapas lipídicas actúan como una barrera para la difusión de iones, el exceso neto de cargas positivas en el exterior y de cargas negativas en el interior produce un potencial de reposo de la membrana de aproximadamente -50 mV a -80 mV. través de la membrana se producen fugas de iones; éstos se desplazan desde las zonas donde su concentración es elevada a aquellas donde es baja: el Na^+ pasa al interior y el K^+ al exterior. Con el tiempo, las concentraciones interna y externa (a ambos lados de la membrana) pueden modificarse. La bomba de Na^+ - K^+ extrae Na^+ del interior de la célula e introduce K^+ , para compensar así las fugas.

La hiperexcitabilidad como fenómeno electroquímico, esta bomba, que moviliza Na^+ y K^+ contra sus gradientes electroquímicos netos, necesita energía, que obtiene a partir de la hidrólisis del trifosfato de adenosina.

La disminución de la negatividad de ese estado polarizado se denomina *despolarización* y su incremento se conoce como *hiperpolarización*.

Los cambios en la permeabilidad de la membrana que permiten la entrada de Na^+ a la célula provocan una despolarización, mientras que aquellos que permiten que el K^+ salga de la célula o que entre Cl^- dan como resultado una hiperpolarización.

Desde una mirada esa interacción química no es más que un evento de transmisión de mensajes vinculados a moléculas neurotransmisoras y cambios localizados de los potenciales de membrana resultado de la acción sobre sus receptores estos cambios potenciales postsinápticos son llamados (PPS), estos pueden ser excitatorios (PEPS) o inhibitorios (PIPS). La característica distintiva de la neurona epiléptica en los modelos experimentales de epilepsia es la despolarización masiva. Durante una descarga interictal, la membrana celular cercana al soma

sufre una despolarización relativamente larga (de 100 μs a 200 μs) y de una amplitud relativamente elevada (aproximadamente de 10 mV a 15 mV), asociada a salvas de actividad de puntas. La despolarización y los trastornos en las membranas neuronales pueden ser un desencadenante. Alteraciones en los flujos de K^+ o Ca^{2+} o cambios en las concentraciones extracelulares de los iones. Estos fenómenos pueden tener lugar no sólo en el microentorno del foco epiléptico, sino también en puntos distantes, a través de las vías sinápticas. Los cambios «corriente abajo» pueden ser los responsables de la generalización de la crisis


DIAGNOSTICO ELECTROENCEFALOGRAFICO (EEG) DE LA EPILEPSIA

Como hemos visto a través del documento el diagnostico neurofisiológico de la epilepsia y la identificación de las descargas eléctricas paroxísticas epiléptiforme focal o generalizada permite una caracterización del síndrome epiléptico. Se utiliza en gran medida para tratar patologías como epilepsia, las encefalopatías, alteraciones del estado de la conciencia. En el caso de la epilepsia, es decisivo el uso de esta herramienta para el diagnóstico, clasificación y control evolutivo del paciente (Ramos-Argüelles, F. 2009). El EEG presenta una serie de oscilaciones que finalmente y dadas ciertas características predefinidas son en su conjunto denominadas ritmos. Su generación obedece a una compleja serie de mecanismos celulares y sinápticos que fueron esbozados con anterioridad para generar una idea del concepto, pero que están por fuera del objetivo del presente artículo.

Un registro típico de EEG consta de varios trazos dispuestos en líneas horizontales cada una de ellas corresponde a un canal con oscilaciones de tiempo (un segundo. s) que van a los distintos ritmos y ondas cerebrales, cada hoja contiene épocas de aproximadamente 10s el conjunto de hojas corresponde a un trazado o registro de un sujeto y el número de hojas dependerá del tiempo de registro, existen equipos entre los 8, 16, 32 y 64 canales. Los PPS tanto los PEPS Y PIPS son de baja amplitud los cuales se magnifican con amplificadores diferenciales para su análisis. (*Análisis visual del electroencefalograma Luis e. morillo2005*).

En la práctica múltiples electrodos se colocan sobre el cuero cabelludo, sin embargo, esta técnica no deja de tener limitaciones ya que se atenúa la amplitud o se contamina con actividad de origen extra-cerebral, artificios o artefactos; músculo, parpadeo, movimiento, sudor, pobre contacto. (fig. 5).

fig.5 tipos de grafoelementos epiléptiformes EEG (tomado de acta



neurológica colombiana vol 22 no. 4 • suplemento (1:1) î 2006 issn 0120-8748 publicación oficial de la asociación colombiana de neurología permiso tarifa postal reducida n° 738).

Ondas

Las ondas cerebrales tienen una lectura en EEG donde nos indica los posibles estados mentales que presenta las principales Beta, Alfa, theta, Gama.

ya que este es realizado sobre la corteza cerebral expuesta. Las ondas de un EEG varían en su frecuencia entre aproximadamente 1-50 Hz y su amplitud 20-1000µV.

Entre los principales ritmos cerebrales básicos y los más relevantes para la práctica experimental tenemos:

- δ (delta): 3,5 Hz
- θ (theta): 4-7,5 Hz
- α (alfa): 8-13 Hz
- β (beta): 13-30 Hz




Fig.6 Múltiples osciladores forman un sistema jerárquico en la corteza cerebral. Parte superior: Espectro de potencia en el EEG del hipocampo durante los periodos de vigilia y sueño. Parte inferior: Clases oscilatorias en la corteza cerebral muestran una progresión lineal de las clases de frecuencia en una escala logarítmica. Buzsáki, G. (2006). Ilustración del sistema jerárquico de osciladores en la corteza cerebral y clases oscilatorias en una escala logarítmica. (Tomada de Rythms of the brain, pág. 114.)

Ondas	Frecuencias	Registro
α	Entre 8 y 13 Hz Amplitud entre 20 y 200 µV	<u>Zona occipital</u> En sujetos normales despiertos, sin ninguna actividad y con los ojos cerrados.
β	β1: Frecuencia doble a las ondas β2	<u>Regiones parietal y frontal</u> Aparecen cuando se activa intensamente el SNC o cuando el sujeto está bajo tensión.
	β2: Frecuencias entre 14 y 30 Hz	
θ	Entre 4 y 7 Hz	En la infancia o en adultos en periodos de estrés y frustración.
δ	Inferiores a 3,5 Hz Amplitud cerca a los 50 µV	Se presentan durante el sueño profundo, en la infancia y en enfermedades orgánicas cerebrales graves.

Tabla 1. Características específicas dependiente del grado de actividad del córtex cerebral Barea, R. (s.f.). Ilustración de los ritmos normales del cerebro en electroencefalografía. (tomada de: <http://www.bioingenieria.edu.ar/academica/catedras/bioingenieria2/arquivos/apuntes/tema%205%20-%20electroencefalografia.pdf>)

Por convención se utiliza un mismo método para colocar los electrodos de superficie sobre el cráneo. Este sistema se conoce como el sistema internacional 10/20 de colocación de electrodos fig8. Mediante este sistema aseguramos que los electrodos se coloquen sobre las mismas áreas, independiente del tamaño de la cabeza.




Fig.7

Diagrama de representación del sistema 10-20. El cerebro es mapeado por cuatro puntos: Nasal, Occipital (inión) y por preauriculares derechos e izquierdo (orejas). (Tomado de Sanei y Chambers, 2007).

Al realizar un registro de la actividad de EEG, podemos identificar una serie de ondas conocidas como ritmos cerebrales. Presentan dos características que las definen: • Frecuencia: hace mención a la periodicidad con la que se repite una onda. Se mide en hercios (Hz). Si una onda presenta una frecuencia de 1 Hz, quiere decir que se repite 1 vez cada segundo (Talamillo García, 2011). • Amplitud: define la magnitud en el cambio de voltaje (µV) medido entre el punto más alto y el más bajo de la onda. A mayor amplitud, más energía se ha aplicado a la onda (Talamillo García, 2011). Los electrodos frontales, centrales, temporales, parietales y occipitales se reconocen con las letras: F, C, T, P y O respectivamente. El subíndice par indica el hemisferio derecho mientras que el impar el hemisferio izquierdo. Así por ejemplo; F3 se refiere al electrodo frontal izquierdo mientras que T4 al temporal derecho. Finalmente, los canales se identifican según los dos electrodos que lo alimentan. Un canal identificado con los electrodos Fp1 - F7 significa que en este canal se amplificará las señales provenientes de la región frontopolar (Fp1) y frontal anterior (F7) del hemisferio izquierdo. La combinación de varios canales y sus respectivas fuentes conforma lo que se conoce como un montaje de registro (Luis e. morillo, Análisis visual del electroencefalograma).

ONDAS CEREBRALES

Beta (14 - 30 Hz)	Alfa (8-13.99 Hz)
Theta (4 - 7.99 Hz)	Delta (0.1 - 3.99 Hz)

tabla. 2 morfología de las ondas (Tomado de Sanei y Chambers, 2007).

PROCESAMIENTO DE LA SEÑAL EEG

Hasta en un 50% de los pacientes con epilepsia se encuentran EEG normales, por tanto, un EEG normal obtenido de un paciente con crisis no descarta el pronóstico de epilepsia merece consideración la gran “sobre interpretación” que existe de los múltiples ritmos cerebrales y de descargas que no tienen connotación alguna. Los prejuicios que conlleva un diagnóstico de epilepsia mal fundamentado afectan desfavorablemente múltiples aspectos sociales, psicológicos e incluso económicos del paciente y su familia (*Epilepsia aspectos clínicos y psicosociales Carlos medina malo 2004*). Normalmente, estas señales se encuentran sin procesar y aparecen con magnitudes muy pequeñas. Por ello deben pasar por varias fases para su depuración debido a que están contaminadas por ruidos e interferencias de los diferentes artefactos, tanto artificiales como biológicos, y así poder extraer la información de mayor relevancia con el estado mental del sujeto en estudio (Sanei y Chambers, 2007). Hoy día, los registros de EEG se obtiene usando sistemas computarizados. Los equipos se encuentran equipados con muchas herramientas de procesamiento de señal y memoria suficiente para realizar registros de larga duración (Sanei y Chambers, 2007). Estos avances en la tecnología digital han permitido el desarrollo del análisis cuantitativo de las señales del EEG, con lo que cabe la posibilidad de estudiar y cuantificar muchos más parámetros a partir de un registro de EEG.

Registrar:

El primer paso llevado a cabo para registrar una onda en el electroencefalograma es emplear unos aparatos conocidos como amplificadores, encargados de aumentar la amplitud de las ondas eléctricas cerebrales. La señal que se obtiene a través de cada uno de los canales de registro debe pasar por una serie de filtros debido a que el rango de información de la señal presenta una frecuencia predominante entre 1 y 40 Hz. Por los tanto, los primeros filtros que se aplicarán tendrán ese ancho, lo que contribuirá a eliminar cualquier interferencia por encima de los 50 Hz de frecuencia (Sanei y Chambers, 2007).

Eliminar artefactos:

El segundo paso es aplicar un algoritmo que se limita a eliminar de la señal aquellos ruidos no deseados provocados por movimientos del paciente. Por otra parte, cuando se trata de un ruido de origen artificial se emplea un filtro denominado “Laplaciano” que detecta las diferencias entre los canales individuales por encima de eventos mayores.

Aplica una operación que le resta a la señal de cada electrodo la media de la señal de sus electrodos vecinos más próximos. Frecuentemente, uno o más de los electrodos producen una salida errónea de información. Para poder eliminarla ese utiliza un algoritmo de limitación para que las señales no deseadas no se tomen en consideración (Boutros, Galderisi y Pogarell, 2011). El tercer y cuarto paso consiste en extraer las características de cada señal. Este paso se lleva a cabo para tener una

primera imagen de la actividad, aplicándole a cada canal un banco de cuatro filtros pasa bandas digitales, que presentan bandas de paso enfocadas en 18 las ondas alfa, beta, delta y theta, que son las más estudiadas en el electroencefalograma. De esta manera, cada señal se transforma en un conjunto de cuatro medidas de potencia (Nunes y col. 2012). El análisis de la electroencefalografía sienta sus pilares principalmente en la amplitud, frecuencia y distribución de la forma de las ondas. Para realizarlo debemos hacer uso de los registros tomados del electroencefalograma.

Estos están formados por señales estacionarias y no estacionarias y de cierta complejidad, cuyas propiedades quedan definidas por el instante de tiempo en el que se analicen. Sin embargo, si solo utilizamos el análisis visual de los registros, no se llegará a extraer toda la información contenida en las señales electroencefalográficas (Sanei y Chambers, 2007).

Análisis espectral o de frecuencias (Algoritmos)

Como y vimos eliminar el ruido es una prioridad en el análisis de datos de los EEG, operación que se realiza utilizando algoritmos. La resolución de un problema exige el diseño de un algoritmo que resuelva el mismo. La propuesta para la resolución de un problema es la siguiente:



Fig.8 Fases del procesamiento de la señal del EEG. En el presente esquema se representación de los distintos pasos a seguir para el procesamiento de una señal registrada en el electroencefalograma (Tomado de Al-Fahoum y Al-Fraihat, 2014)

Una manera muy común de describir el EEG es en términos de bandas de frecuencia y para poder realizarlo se necesita cuantificar la frecuencia. La primera persona interesada y que propuso una solución frente a este problema fue Joseph Fourier cuyo teorema decía que “toda señal periódica puede descomponerse en una serie de ondas seno y coseno, que al sumarse entre ellas producen la señal original” (Urrestarazu e Iriarte, 2005).

Según su teorema “toda señal periódica se puede descomponer en un conjunto de ondas seno y coseno, que sumadas entre sí reproducen la señal original” (Urrestarazu e Iriarte, 2005). Este método, en concreto la transformada rápida de Fourier (FFT), es el más empleado en este tipo de análisis. Todos estos métodos asumen que no varía el contenido en frecuencia de la señal estudiada, lo que limita su análisis a señales estacionarias. Esta se sigue considerando su principal limitación, a pesar de haberse desarrollado variantes como la transformada en ventana de Fourier (WFT), encargada del estudio de cambios de frecuencias en el tiempo (Cortés, Medina y Chávez, 2007). El análisis de Fourier está basado en la idea de que una señal continua presenta un número finito de frecuencias y, gracias a ello, puede descomponerse en un número finito de ondas. Para agilizar el cálculo, se emplea el algoritmo de la FFT a una serie de muestras, aunque esto no es necesario actualmente gracias a la potencia de cálculo de

los ordenadores (Freeman y Quiroga, 2013). Si agrupamos todas esas ondas seno extraídas de la señal del EEG, obtendremos su espectro de frecuencia. Por lo tanto, es posible estudiar las señales electroencefalográficas en el dominio de tiempo y, además, en el de frecuencia (Blanco y col., 1995).

A diferencia de la transformada rápida de Fourier, la WFT aplica la transformada a periodos de tiempo sucesivos y de corta duración, para solucionar el problema en señales no estacionarias, pero presenta ciertas limitaciones ante el análisis de frecuencias bajas (Muthuswamy y Thakor, 1998).

Además de estos métodos que acabamos de mencionar, se han desarrollado diversos métodos de análisis de tiempo-frecuencia, que permiten valorar la evolución temporal comprendida en los cambios de frecuencia.

Entre ellos se encuentra la transformada de wavelet (TW) y la expansión de Gabor. A diferencia del análisis de Fourier, estos separan la distribución de energía de una señal en distintos componentes de frecuencia en el tiempo (Rosso y col., 2006) (véase figura 8). Este análisis puede interpretarse como un banco de filtros, con un ancho de banda proporcional a su frecuencia. De esta forma, la resolución temporal aumenta a frecuencias altas, y la resolución de frecuencias a bajas (Samar et al., 1999).

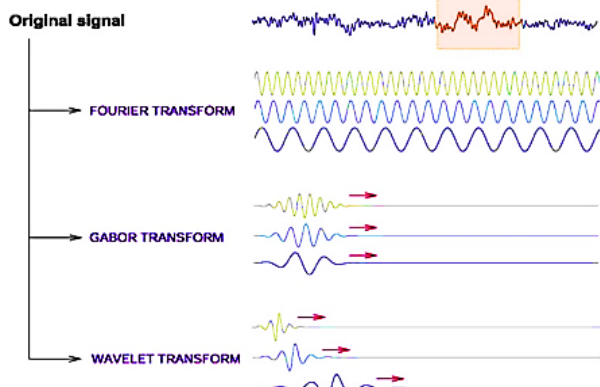


Fig.9 - Ideas básicas de Wavelets. La Transformada de Fourier es el producto interno de la señal y sinusoides de diferentes frecuencias. Para conseguir resolución en el tiempo; la transformada de Gabor (o de corto tiempo de Fourier) usa sinusoides de ventana estrechados con funciones Gaussianas. Con wavelets, estrechando o comprimiendo una función, el tamaño de la ventana es variable y se obtiene una comprensión entre el tiempo y la resolución frecuencial para todas las frecuencias (Tomado de Freeman y Quiroga, 2013).

METODOLOGÍA

Se realiza una búsqueda en bases de datos con el fin de encontrar soluciones para la detección automática de la epilepsia con estudios de métodos algorítmicos de extracción de características y métodos clasificadores en las señales EEG de los últimos 20 años; todos los artículos de trabajos experimentales, los datos se seleccionaron de búsquedas con terminología clave de epilepsia; electroencefalograma; detección; detección automática, para un total de 17 artículos. Consecutivamente los

artículos destacados se dividieron en etapas de artículos por años así:

Primera etapa del año 2000-2005, segunda etapa 2006-2010, tercera etapa 2011-2015, cuarta etapa 2016-2019.

PRIMERA ETAPA (2000-2005) UN ENFOQUE DE MÚLTIPLES FASES Y MÚLTIPLES MÉTODOS PARA LA DETECCIÓN Y CLASIFICACIÓN AUTOMÁTICA DE EEG EPILEPTIFORMES.

Los autores He Sheng Liu, Tong Zhang, y Fu Sheng Yang crean un sistema que consta de dos fases principales: una fase de selección preliminar en la que los datos se reducen significativamente, seguido de una fase analítica. A diferencia de la mayoría de los sistemas que solo se enfocan en transitorios agudos, este sistema también tiene en cuenta las ondas lentas.

Este estudio propone un sistema robusto que combina múltiples métodos de procesamiento de señal en un esquema de múltiples fases, que integra el filtrado adaptativo, la transformada de onda, la red neuronal artificial y el sistema experto. Diagrama de bloques fig10.

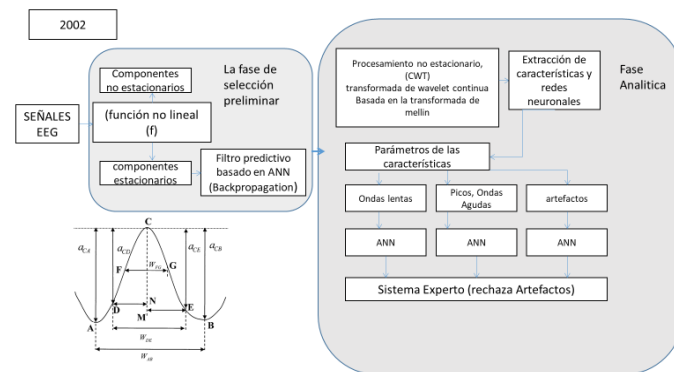


Fig.10. diagrama de bloques del artículo. Elaboración propia

El sistema se evaluó con datos de pruebas de 81 pacientes, Los registros variaron de 4 a 24 h de duración con un total de más de 800 horas de grabaciones.

Los datos contenían todos los tipos de actividades epileptiformes, incluidos EEG epilépticos no focales y focales, por ejemplo, picos simples, estallidos de picos, estallidos de ondas de picos y picos, ondas nítidas, estallidos de ondas lentos y oleadas de lentos, todo en diversas amplitudes. El 90.0% de los eventos epilépticos fueron detectados correctamente.

1) La tasa de detección de eventos transitorios agudos fue del 98,0% y la tasa global de falsa detección fue del 6,1%. La tasa de muestreo fue de 100 Hz y la precisión de conversión fue de 8 bits. En este documento también se desarrolla un filtro no lineal para la separación de componentes de EEG estacionarios y no estacionarios, en dos fases. La fase de selección preliminar que selecciona las ondas sospechosas para su posterior procesamiento con el fin de reducir en gran medida los datos a analizar más. La técnica no lineal combinada con la predicción adaptativa se desarrolla para este propósito. Aquí, utilizamos ventanas largas de 10 s para segmentar el EEG continuo sin procesar.

2) La fase analítica emplea múltiples métodos para detectar y clasificar las ondas epilépticas de los segmentos sospechosos seleccionados por la primera fase. Los segmentos con diferentes longitudes seleccionados de la primera fase se analizan individualmente mediante la transformación de wavelet y la red neuronal artificial, luego todos estos segmentos individuales en el rango de la ventana de 10 se someten a un sistema experto para formar complejos, o para rechazar artefactos, etc.

Para probar la eficacia del examen preliminar, se procesaron ocho registros de EEG de 16 canales de 1 hora de duración de ocho pacientes epilépticos típicos. Los resultados fueron comparados con el informe realizado por expertos humanos. De acuerdo con esta prueba, todos los 1018 transitorios agudos y 9117 de las 9398 ondas lentas fueron detectados por la fase de selección preliminar. En esta fase, la tasa de detección de onda lenta fue de 97.0%, y la tasa de detección de todas las ondas epilépticas fue de 97.3%, mientras que el volumen de datos se redujo a aproximadamente 25%.

El sistema experto explota completamente la información contextual espacial y temporal para rechazar artefactos. Se combinan varias reglas heurísticas para distinguir los artefactos (como el parpadeo del ojo, el movimiento de los electrodos u otros artefactos) de las ondas epilépticas. A partir de entonces, algunas ondas aisladas se reconstruyen en complejo de pico y lento o complejo de fuerte y lento. Finalmente, se toma la decisión de si la onda es un tipo de onda epiléptica y, de ser así, a qué tipo pertenece. La transformada de wavelet discreta (DWT) se usa ampliamente porque exige relativamente menos computación en comparación con la transformada de wavelet continua (CWT). La principal limitación de DWT es la rugosidad de su incremento de escala que se duplica entre dos niveles adyacentes. Sin embargo, CWT puede lograr un muestreo de escala más fina para poder analizar la señal con una adoptamos en nuestro sistema EEG.

En el análisis por computadora, todos los eventos que tienen una proximidad mayor que un umbral se informaron y compararon con el resultado de la revisión humana. El umbral se estableció en 0.80 para lograr un mejor compromiso entre la sensibilidad y la especificidad de nuestros datos de entrenamiento (excepto las ondas lentas durante las etapas de sueño, para estas ondas el umbral fue de 0.95). el documento también proporciona una interfaz de usuario que permite al usuario multiplicar un factor ψ al umbral, por lo que el umbral final será ($0.8 \times \psi$). Al ajustar el factor ψ , el lector de EEG puede cambiar manualmente el umbral para lograr un mejor resultado en un tema específico cuando sea necesario.

Se dividen estos 81 registros en tres grupos.

Grupo 1) Registros dominados por olas lentas.

Grupo 2) Registros dominados por picos, ondas agudas y complejos.

Grupo 3) Registros contaminados por muchos artefactos. Las entradas de la red son los parámetros de función adquiridos anteriormente y la salida indica la proximidad entre la entrada como son.

*El potencial Diferencia entre el pico y los puntos de inflexión divididos por la amplitud de fondo.

*Diferencia de voltaje entre el pico y los valles de una onda dividida por la amplitud de fondo

En el Grupo 1, los picos y las ondas afiladas rara vez aparecieron Las olas lentas se convirtieron en la indicación más importante de los acontecimientos. Como las ondas lentas se consideraron y las actividades epileptiformes se pueden señalar correctamente.

Los registros en este grupo tuvieron una duración de 450 h, en el que expertos humanos encontraron 86 434 eventos. El 88.9% de estos eventos fue detectado por el sistema y la tasa de detección falsa fue de 5.6%.

Los resultados fueron comparados con el informe

La tasa de detección de todos los eventos epilépticos fue tan alta como 92.4% con una tasa de detección falsa de 6.4%. Aunque se ha prestado mucha atención a las ondas lentas, no se han descuidado en absoluto los transitorios agudos. Los resultados muestran que nuestro sistema es muy sensible a los transitorios agudos.

El grupo 2 contenía muchos picos, ondas agudas y complejos, y también una gran cantidad de ondas lentas. Los registros en este grupo sumaron hasta 350 h de duración, incluidos 48 841 eventos. El 98,0% de los transitorios agudos se detectaron correctamente. La tasa de detección de todos los eventos epilépticos fue tan alta como 92.4% con una tasa de detección falsa de 6.4%. Aunque se ha prestado mucha atención a las ondas lentas, no se han descuidado en absoluto los transitorios agudos. Los resultados muestran que nuestro sistema es muy sensible a los transitorios agudos.

El Grupo 3 contenía muchos artefactos que generalmente obstaculizan el sistema de detección automática, Los registros en este grupo ascendieron a 60 h de duración. La tasa de detección en este grupo alcanzó el 88,2% y la tasa falsa fue del 10,1%. Se puede inferir que el sistema rechaza los artefactos satisfactoriamente. La tasa de detección general de los picos, ondas agudas y complejos fue del 98,0% cuando se combinaron los resultados de los tres grupos. También resultó satisfactorio para el reconocimiento de ondas lentas, aunque son más difíciles de detectar en comparación con los transitorios agudos; La tasa de detección de onda lenta fue del 86,8%. En general, el 90.0% de las ondas epilépticas fueron correctamente discriminadas y clasificadas, mientras que la tasa falsa se mantuvo en 6.1%.

Se trazo la curva de características operativas del receptor (ROC) para evaluar el rendimiento del sistema en todo el conjunto de datos de prueba. En este sistema, el umbral final para la detección de ondas epilépticas es ($0.8 \times \psi$). Varía el factor ψ paso a paso en el rango y se calcula la tasa de detección y la tasa falsa en cada paso. Luego, se obtiene la curva ROC como. El área bajo la curva ROC es aproximadamente del 95%. El área bajo la curva ROC refleja la compensación entre sensibilidad y especificidad; un área más grande indica una mejor capacidad de discriminación del sistema. El área grande bajo nuestra

curva ROC ha demostrado que el sistema puede tener alta sensibilidad y alta especificidad al mismo tiempo.

Se llegó a la conclusión de que este sistema tiene un buen rendimiento en la detección de actividades epileptiformes y el enfoque de múltiples fases es una forma adecuada de resolver este problema, aunque es poco probable que la detección de picos utilizando datos de EEG sin procesar como entrada de ANN sea factible con la tecnología informática actual.

DETECCIÓN AUTOMÁTICA DE EVENTOS EPILEPTIFORMES EN EEG POR UN PROCEDIMIENTO DE TRES FASES BASADO EN REDES NEURONALES ARTIFICIALES

Los autores Nurettin, Ibrahim Öztura, Mehmet Kuntalp, Baris Baklan y Cüneyt Güzelis presentan un procedimiento de tres fases basado en redes neuronales artificiales (ANN) para la detección automática de eventos epileptiformes (EVs).

Los datos del EEG utilizados en este estudio se obtuvieron de 29 pacientes epilépticos que habían estado bajo evaluación y tratamiento en el Departamento de Neurología del Hospital Universitario Dokuz Eylül, İzmir, Turquía. 19 de estos registros EEG fueron utilizados en la formación, mientras que el restante 10 en las pruebas. Los datos se obtuvieron de un sistema de monitorización EEG clínica, que almacena datos de EEG continuos en su disco duro. Los datos del EEG fueron adquiridos con electrodos de disco de Ag / AgCl colocados mediante la norma internacional 10-20 y se obtuvieron durante la etapa de vigilia tranquila; Dos de ellas contenían actividad epileptiforme generalizada. Los restantes registros de EEG contenían actividad epileptiforme focal.

Todos los registros de EEG habían sido vistos de forma independiente por dos evaluadores (EEGers). Los evaluadores EEGers etiquetaron a los candidatos con epilepsia transitoria (ET) como una actividad epileptiforme de un solo canal en los 19 canales elegidos para procedimientos de entrenamiento. Luego, los candidatos ET, para los cuales no hubo acuerdo entre los dos EEGers, fueron tratados como EEG de fondo.

Los EV de varios canales también fueron determinados por los mismos EEG con el mismo consenso mencionado anteriormente.

La duración total de los registros de EEG fue de 11 horas y 6 minutos (promedio de 22,1 minutos) y las edades de los pacientes variadas de 2 a 69 años (promedio de 28 años). Estos registros de EEG tuvieron una duración promedio de 22.7 minutos y una duración total de 7 horas y 18 minutos. Los pacientes tenían una edad media de 29 años. Los evaluadores EEG determinaron 216 eventos epileptiformes (EV) en el conjunto de entrenamiento. Los 10 registros EEG restantes se usaron para probar el Rendimiento del sistema entrenado. Estos registros tuvieron una duración promedio de 20.8 minutos y una duración total de 3 horas y 48 minutos.

Se determinaron noventa y tres EV para el procedimiento de prueba. Los pacientes de este grupo tenían una edad media de 26 años. Las grabaciones se obtuvieron de 19

canales con frecuencia de muestreo de 256 Hz y paso de banda filtrado entre 1 y 70 Hz.

En este documento, se presenta una detección automática de EV en una señal de EEG multicanal diagrama de bloques del artículo fig. 11.

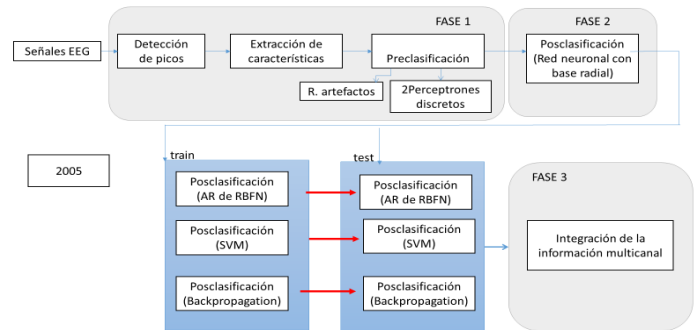


Fig.11. diagrama de bloques del artículo en tres fases. (Elaboración propia).

PRIMERA FASE

El primer paso sería la extracción de los picos del registro. Para detectar picos, primero tomamos el promedio de la señal completa y lo restamos de la señal original. Esto se hace no solo para la detección de picos, pero también para el resto del procedimiento. Luego calculamos la derivada temporal ver ecuación (1) de la señal $F(t)$ y encontramos sus cruces por cero. Esto se puede lograr para una señal discreta buscando los puntos de inflexión según los criterios dados.

$$f[n] = f(t) \quad t = nT \quad (1)$$

Aunque los dos lados pueden tener una longitud desigual, la duración de un ET es siempre entre 20 y 70 ms. Esta duración puede definirse como la suma de la primera y segunda duración de media onda, utilizando un mecanismo de umbral simple da como resultado una representación lineal por partes que conecta los picos sucesivos restantes, este se usa solo para extraer las características que serían alimentadas al pre-clasificador. Las características utilizadas como entrada para el pre-clasificador son: primera amplitud de media onda (FHWA), segunda amplitud de media onda (SHWA), primera duración de media onda (FHWD), segunda duración de media onda (SHWD), primera pendiente de media onda (FHWS) y segunda pendiente de media onda (SHWS). El pre-clasificador se realiza para eliminar los no ET definidos y también para capturar los ET definidos. Los picos restantes correspondientes a posibles ETs y posibles no ETs son las únicas entradas del pos-clasificador. De esta manera, no solo se reduce el tiempo de cálculo de todo el procedimiento de clasificación, sino que también se aumenta el rendimiento de detección general.

La reducción de artefactos se hace mediante la discriminación de amplitudes de 50 Hz y se pasan por mecanismo de umbral si la longitud de un segmento siguiente y anterior, y si este segmento también tiene una amplitud y una duración menores de 2 y 20 ms, respectivamente.

Entonces se etiquetan los picos asociados con ese segmento se usa la regla de aprendizaje discreto de perceptrones, con dos perceptrones que son alimentados por las seis características antes mencionadas separa con éxito los posibles eventos no definidos epileptiformes transitorios (ET) de las ET definidas en otras palabras, las ET posibles y las no ET posibles están separadas de las ET definidas y las ET no definidas en esta fase.

SEGUNDA FASE:

El pos-clasificador su función es separar los picos en el tercer grupo, posibles ET y posibles no ET, entre sí es, decir ET de las cuales no se tiene certeza. Para esto usan tres ANN diferentes, un perceptrón multicapa de Backpropagation (MLP), una red de función de base radial (RBFN) entrenada por el método híbrido y una máquina de vector de soporte de base radial (RB) SVM), están contruidos para funcionar como un pos-clasificador. Se utiliza un RBFN con una unidad de salida de limitador rígido como pos-clasificador. El RBFN se entrena mediante el método híbrido. En primer lugar, los centros de las unidades ocultas se determinan mediante un método de prueba y error, En lugar de las seis características utilizadas en el entrenamiento del pre-clasificador, los datos brutos en ventana asociados con cada pico se envían al RBFN. Este procedimiento de clasificación posterior también se realiza, RB-SVM y MLP de Backpropagation basados en auto-regresivos (ANN), y los resultados se comparan en términos de su rendimiento de clasificación.

El mejor rendimiento se obtiene con el RB-SVM que proporciona una sensibilidad promedio de 89.1%, una selectividad promedio de 85.9%, y una tasa promedio de detección falsa (por hora) de 7.5.

En la fase de preclasificación, el 80% de los picos se ubican en el primer y segundo grupo. El 20% restante de los picos, que pertenecen al tercer grupo, se da como entrada al pos-clasificador.

Tercera fase, La fase final del sistema de detección de picos combina las salidas del pos-clasificador de tal manera que confirme la presencia de un EV a través de dos o más canales del EEG. Los ET en diferentes canales generalmente tienen patrones similares, pero sus picos pueden no aparecer exactamente al mismo tiempo, es decir, podría ocurrir un retraso de tiempo entre dos picos. Por lo tanto, la localización de esa actividad también debe tenerse en cuenta para la integración de información multicanal.

La información multicanal se integra para identificar EVs. De esta manera, la fase final del sistema de detección de picos combina los resultados del pos-clasificador para tomar una decisión sobre la presencia de un EV.

El rendimiento general del sistema se determina con respecto a los EV confirmados después de la integración de la información multicanal.

La evaluación visual realizada por dos EEGers de 19 registros de EEG de canal de 10 pacientes epilépticos muestra que el mejor rendimiento se obtiene con el RB-SVM que proporciona una sensibilidad promedio de 89.1%,

una selectividad promedio de 85.9%, y una tasa promedio de detección falsa (por hora) de 7.5.

En la fase de preclasificación, el 80% de los picos se ubican en el primer y segundo grupo. El 20% restante de los picos, que pertenecen al tercer grupo, se da como entrada al pos-clasificador. El RBFN muestra una sensibilidad media de 87,4%, una selectividad promedio de 84.0%, y una tasa promedio falsa detección (por hora) de 10,2 RBFN basados en AR en 87,5% de sensibilidad media, 84,0% de selectividad promedio, y la tasa de detección de falsos promedio de 10,1. Por lo tanto, el rendimiento de la RBFN basados en AR es aproximadamente la misma con el rendimiento de la RBFN. Por tanto en el conjunto de pruebas muestra que el mejor rendimiento se obtiene con la RB-SVM ya que la RB-SVM como el pos-clasificados muestra una sensibilidad media de 89,1%, una selectividad media de 85,9%, y una tasa de detección de falsos promedio (por hora) de 7,5. Tiempo de cálculo para un registro multicanal de 42,8 min a largo también se encuentra en alrededor de 2 min 50 s para la RB-SVM demostrando que las RNA pueden ser entrenados para reconocer cambios eléctricos.

SEGUNDA ETAPA (2006-2010)

DETECCIÓN Y CLASIFICACIÓN DE EVENTOS TRANSITORIOS DE EEG MEDIANTE REGLAS DE ASOCIACIÓN

El objetivo del artículo es abordar una metodología satisfactoria Para la clasificación de las puntas epilépticas y cuatro tipos de eventos transitorios (picos epilépticos, actividad muscular, actividad de parpadeo de los ojos y agudo) en los registros de EEG.

Mediante la lectura de registros EEG. Evaluando reglas de asociación, una técnica para la detección automática de eventos en los picos epilépticos.

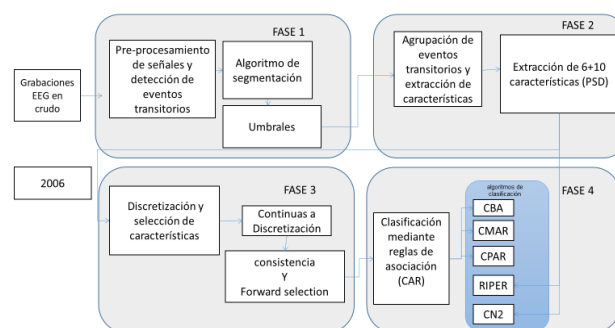


Fig.12. diagrama de bloques del artículo. (Elaboración propia).

Como metodología se usaron las reglas de asociación en registros EEG de 25 sujetos 12 con actividad epiléptica normal y 13 epilépticos, con edades entre los 16 a 76 años, la duración de los EEG fue de aproximadamente 15 min, los datos de los EEG fueron tomados con colocación de electrodos de acuerdo a normas estándar 10-20 internacional, con discos de Ag/ Ag Cl. De forma sincrónica se registran dieciséis canales con un paso de banda de 1,6 y 70Hz incluyendo un filtro de 50Hz. La frecuencia de muestreo fue de 256Hz con resolución de 12 bits, la toma de la muestra se realizó mientras los pacientes estaban despiertos, pero en reposo e incluyen periodos ojos abiertos ojos cerrados, hiperventilación y estimulación

fónica cerrados y abiertos. En el Departamento de Neurología del hospital Universitario de Ilo-Ilo y un sistema de monitoreo EEG Medelec no invasivo. Una base de datos que resulto de 858 eventos transitorios tabla2.

CATEGORIAS	N° DE EVENTOS
puntas epilépticas (ESS)	274
actividad muscular (EMG)	254
actividad de parpadeo de los ojos (EOG)	81
actividad alfa aguda (SAA)	249
TOTAL	858

tabla.2. eventos transitorios totales encontrados en el artículo. (elaboración propia)

Para estos resultados fue necesario pasar por cuatro fases de asociación: la detección de eventos transitorios; Agrupación de eventos transitorios y extracción de características; Discretización y selección de características; Clasificación mediante reglas de asociación.

-Primera fase: preprocesamiento de la señal del EEG se realizó con el fin de detectar los eventos transitorios, se utilizó un algoritmo de segmentación para eliminar las áreas de baja actividad de fondo y detectar eventos transitorios en las grabaciones de EEG, mediante la utilización de Umbrales se eliminaron las áreas de baja actividad Los picos por encima del umbral calculado (t) se consideraron eventos transitorios. Se aplicó una ventana con una longitud constante de 91 puntos de datos (~355 ms), centrada en cada pico identificado; (la razón para usar la longitud de ventana especificada es que los picos tienen duraciones de 20-70 ms, las ondas agudas duran 70-200 ms, Las ondas EMG son menos de 30 ms, y las ondas EOG duran más de 150 ms). Finalmente, si se encontró un pico más grande (vértice) en la ventana, la ventana se centró en este pico; de lo contrario, se consideró la ventana de 91 puntos de señal como un evento transitorio.

-Segunda fase: los eventos se agruparon en eventos de tipo transitorio, y dieciséis características representativas se extrajeron de cada prototipo así: después de la agrupación, cada grupo está representado por un prototipo, que se calcula como el centroide de los patrones que pertenecen a ese grupo todo se hace de manera iterativa. En este trabajo, se utilizan dieciséis funciones para caracterizar cada evento transitorio prototipo. Seis de ellos, a saber, la duración, el área, la pendiente promedio, la nitidez, la desviación estándar y la frecuencia dominante se han utilizado previamente. En su trabajo, se extrajeron diez características más de la densidad del espectro de potencia (PSD) de cada evento transitorio prototipo. Más específicamente, el PSD de cada evento transitorio prototipo se dividió en diez rangos de frecuencia distintos. Se obtiene el promedio de la PSD para cada rango (densidad de espectro de potencia discreta) y se forman diez características (denominadas disco PSD 1 a disco PSD 10).

-tercera fase: las características valoradas continuas extraídas se transformaron en las discretas utilizando una técnica de discretización con un enfoque que se basa en la minimización de entropía, y el principio de longitud mínima de descripción requerida debido al uso también de minería de reglas de asociación de clasificación, que será usada en la cuarta fase, y se identificó un subconjunto de características más consistente. De las 16 características originales la discretización obtiene los siguientes valores discretos: seis valores de característica para desviación estándar, seis para pendiente promedio, nueve para nitidez, cinco para duración, seis para frecuencia dominante, cinco para área, seis para disco PSD 1, cinco para disco PSD 2, cinco para disco PSD 3, tres para disco PSD 4, tres para disco PSD 5, tres para disco PSD 6, ocho para disco PSD 7, tres para disco PSD 8, cinco para disco PSD 9 y dos para disco PSD 10.

El problema de la selección de características se define de la siguiente manera: encuentre un conjunto mínimo de características relevantes de W que describa el conjunto de datos, así como las características originales de Z , donde $W \leq Z$ ($Z = 16$ en este caso). Este proceso se hace mediante cuatro pasos: generación de subconjuntos, evaluación de subconjuntos, aplicación de un criterio de detención y validación de resultados; enfoque de filtro, la mejor precisión se informó utilizando el método de evaluación del subconjunto basado en la consistencia, que selecciona un subconjunto con características de mejor coherencia con la clase.

Y un enfoque de envoltura forward selección; El subconjunto que se genera a partir de la selección de características consta de ocho ($W = 8$) características. Estas características son: desviación estándar, pendiente promedio, frecuencia dominante, duración, área, y en el rango de densidad discreta los discos PSD 3, disco PSD 4 y disco PSD 9. Estas características son las más útiles y ampliamente utilizadas por los expertos para decidir la clasificación de un evento transitorio según el documento.

-cuarta fase: clasificación utilizando reglas de asociación se realizó para la categorización evento transitorio. Esta es tal vez una de las fases más importantes ya que emplea las reglas cuyo consecuente es la clase. Estas reglas se denominan reglas de asociación clase (CAR) y, después de su generación, se usan para generar un modelo de clasificación. En esta fase de clasificación se implementaron tres métodos algorítmicos para detección epiléptica

CBA: clasificación basada en asociaciones con efectividad de (87.38%)

CMAR: La clasificación basada en múltiples algoritmos de reglas de asociación, utilizando chi-cuadrado ponderado el cual tabula una variable en categorías comparando frecuencias observadas y esperadas. Efectividad 85.98%

CPAR: La clasificación basada en reglas de asociación predictivos que genera un pequeño conjunto casos cubiertos por una regla que satisfagan sus condiciones. Su efectividad fue del 86.45%. Los algoritmos anteriores se aplican de manera similar. Extraen reglas de asociación de clase que tienen como antecedente un subconjunto (o

todas) de las ocho características (subconjunto reducido) de cada prototipo con su valor discreto respetado y, como consecuencia, la clase del prototipo. La forma de esos CAR es fig16:

$$IF F_1 = DV_1 \text{ AND } F_2 = DV_2 \text{ AND } \dots \text{ AND } \quad (2).$$

$$F_M = DV_N \text{ LUEGO el evento transitorio es } C_i$$

para la obtención las reglas de asociación de clase: donde F_i denota una de las ocho características del subconjunto de características más consistente, DV_i denota uno de los valores discretos de esta característica y C_i denota una de las cuatro clases de eventos transitorios (ES, EMG, EOG, SAA).

Además de estos tres algoritmos, se examinan otros dos algoritmos. La poda incremental repetida para la reducción de errores (RIPPER) y el algoritmo CN2.

Estos algoritmos extraen reglas del conjunto de entrenamiento sin requerir la discretización de las características de valor continuo. Por lo tanto, los algoritmos se aplican al subconjunto de características más consistente, utilizando los valores continuos de esas características.

RIPPER: La poda incremental repetido para producir la reducción de errores. Con el 85.95% de efectividad

CN²: Extraer las reglas de conjunto su utilización es con el fin de analizar datos con ruido. Su efectividad fue del 82.48%, Ver Tabla3.

Algorithm	Transient Event	Sen ¹ %	Spe ² %	Sel ³ %	Acc ⁴ %
CBA	ES	86,13	91,75	83,1	87,38
	EMG	91,34	97,34	93,55	
	EOG	77,5	99,23	91,18	
	SAA	87,9	93,75	85,16	
CMAR	ES	80,29	92,1	82,71	85,98
	EMG	91,34	97,67	94,31	
	EOG	87,5	99	89,74	
	SAA1	86,3	91,45	80,45	
CPAR	ES	85,4	91,41	82,39	86,45
	EMG	90,55	97,01	92,74	
	EOG	82,5	99,74	97,06	
	SAA	84,68	92,43	82,03	
RIPPER	ES	86,86	87,97	77,27	85,05
	EMG	89,79	98,01	95	
	EOG	87,5	99,48	94,59	
	SAA	77,42	93,09	82,05	
CN2	ES	92,7	79,73	68,28	82,48
	EMG	86,61	99,34	98,21	
	EOG	80	99,74	96,97	
	SAA	67,74	95,72	86,6	

Tabla 3. (Tomada de "EEG Transient Event Detection and Classification Using Association Rules).2006

En todos Se utilizaron cuatro medidas de evaluación: la sensibilidad (Sen), especificidad (Spe), la selectividad (Sel), y la precisión (Acc). A saber, las medidas comúnmente usadas para evaluar los algoritmos y métodos usados están dados por:

$$Accuracy (Acc) = \left(\frac{TP+TN}{TN+FN+TP+FP} \right) X100 \quad (3)$$

$$Sensitivity (Sen) = \left(\frac{TP}{TP+FN} \right) X100 \quad (4)$$

$$Specificity (Spe) = \left(\frac{TN}{TP+FN} \right) X100 \quad (5)$$

Donde:

- 1) Verdadero positivo (TP): personas enfermas diagnosticadas correctamente como enfermas entonces el segmento de ráfaga se ha detectado correctamente.
- 2) Falso positivo (FP): personas sanas identificadas incorrectamente como enfermas óseas que un segmento normal detecta incorrectamente como segmento de ráfaga.
- 3) Verdadero negativo (TN): personas sanas identificadas correctamente como sanas es decir que un segmento normal (sin ráfaga) se detecta correctamente.
- 4) Falso negativo (FN): personas enfermas identificadas incorrectamente como sanas significa que un segmento de ráfaga se detecta incorrectamente como segmento normal.

Como mejora para el método es hacer una mejor descripción del evento EEG extrayendo más y mejores características como datos demográficos e historial del paciente.

METODOLOGÍA MIXTA DE RED WAVELET-CAOS-NEURAL PARA LA DETECCIÓN DE EPILEPSIAS Y ATAQUES EPILEPTICOS

Los autores Samanwoy Ghosh-Dastidar, Hojjat Adeli. muestran una metodología para la clasificación de electroencefalogramas, en el documento se pretende 1) diseñar un espacio de características apropiado mediante la identificación de combinaciones de parámetros que aumentan la separación entre clases y 2) diseñar un clasificador que pueda modelar con precisión el problema de clasificación basado en el espacio de características seleccionado. Integrando simultáneamente Wavelets, teoría del caos y redes neuronales para el análisis de EEG. El objetivo final de esta investigación es el monitoreo en tiempo real de los EEG y la predicción de ataques.

las señales de EEG se recopilan de una base de datos disponibles en línea por el Dr. Ralph Andrzejak, del Centro de Epilepsia de la Universidad de Bonn, Alemania. El conjunto de datos comprende cinco conjuntos de grabaciones de EEG de un solo canal de 100 segmentos EEG denotadas por A, B, C, D y E o (Z, O, N, F, y S) para otros trabajos equitativamente. La longitud de cada señal es de 23,6 s. Los datos se transfirieron a un entorno digital a una frecuencia de muestreo de 173.61 Hz. (un total de 4097 muestras) después de convertirse con un convertidor digital analógico de 12 bits, La grabación de señales EEG se realiza utilizando un sistema de amplificador de 128 canales idéntico, utilizando una referencia común promedio. Después de la grabación, el filtrado de paso de banda de los datos del EEG se realizó con la configuración del filtro mantenida entre 0,53 y 40 Hz. Cada conjunto de datos contiene 100 segmentos EEG de un solo canal. Las señales de EEG de los conjuntos A y B se adquieren de la colocación del electrodo de superficie utilizando el sistema

de electrodo estándar 10-20 de cinco voluntarios sanos en estado despierto y relajado con ojos abiertos y ojos cerrados, respectivamente. Las señales de EEG de los conjuntos C se registran desde la formación del hipocampo en el hemisferio opuesto de pacientes enfermos antes de las convulsiones y la de los conjuntos D se registra desde la zona epileptogénica en los pacientes enfermos antes de las convulsiones, respectivamente. Ambos conjuntos C y D comprenden la actividad en los intervalos libres de ataques, mientras que el Conjunto E consiste únicamente en actividades de ataques de voluntarios enfermos. Un ordenador con microprocesador Intel (R) Core i7-2670QM2.20-GHz y se utiliza 8-GB RAM para la solución de problemas. (Andrzejak 2001).

Para este artículo los datos de EEG utilizados fueron de tres grupos diferentes: normal, interictal e ictal, disponibles un total 300 EEG.

La misión de Wavelet fue descomponer la señal en cinco sub-bandas delta, theta, alfa, beta y gamma para un total de seis puntos de datos incluyendo datos EEG puros a los cuales se aplican tres parámetros desviación estándar (STD) o (SD) (cuantificación de la varianza de la señal), dimensión de correlación (CD) y mayor exponente de Lyapunov (LLE) (cuantificación de la dinámica caótica no lineal de la señal). En consecuencia, cada señal está representada por un punto en un espacio de características 1D a 3D. Este análisis se denomina análisis específico de la banda, en este artículo y el espacio de la característica correspondiente se conoce como el espacio de la característica específica de la banda. En la segunda fase, la investigación continúa con los clasificadores y combinaciones más prometedoras de dieciocho

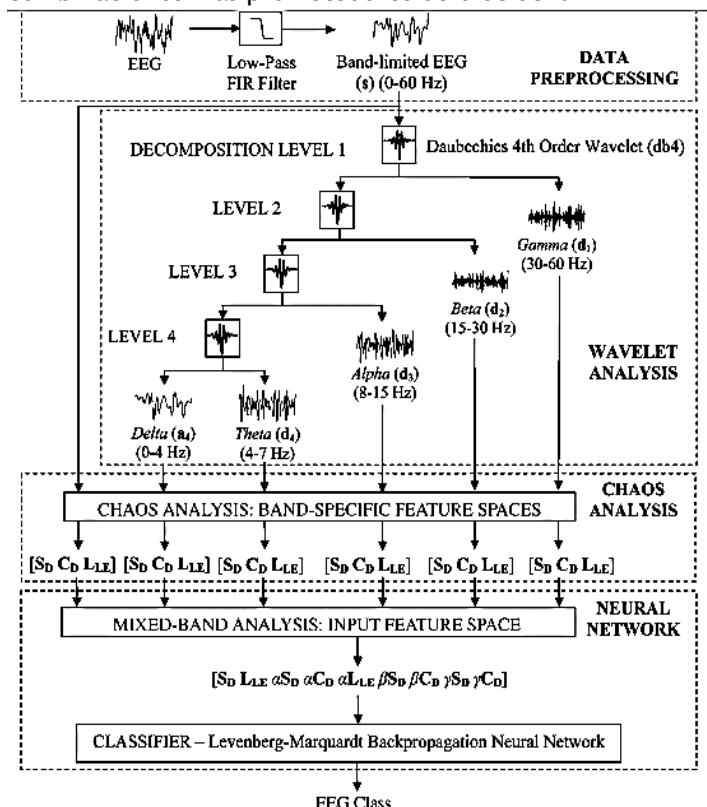


Fig.13. diagrama de bloques en cuatro fases (Tomado de Mixed-Band Wavelet-Chaos-Neural Network Methodology for Epilepsy and Epileptic Seizure Detection).

parámetros seleccionados de los seis tipos de sub-bandas de EEG y EEG en el primer paso. Para el análisis wavelet-caos, las dimensiones del espacio de entrada son $N \times 6 \times 3K$ (N puntos de datos por EEG o sub-banda EEG, seis EEG y sub-bandas EEG y tres grupos K de EEG).

Después del análisis wavelet-caos, cada EEG se representa como un punto de datos dimensionales en el espacio de entrada reducido, F, que se denomina espacio de características. Las dimensiones del espacio de características son $P \times 3K$, donde $P \in \{1 \text{ a } 18\}$ se selecciona de los tres parámetros (STD, CD y LLE representados por los vectores (de tamaño K) SD, CD LLE y) obtenidos de la banda limitada EEG, así como sus cinco sub-bandas (total de $6 \times 3 = 18$) Como resultado, cada EEG está representado por un punto en un espacio de características de 2-D a 18-D. Esto se denomina análisis de banda mixta en esta investigación y el espacio de características correspondiente se denomina espacio de características de banda mixta.

Clasificadores

Para este ejercicio se disponen cuatro métodos clasificadores:

- K-medias de agrupación
- Discriminant Analysis (LDA)
- red neural de función de base radial RBFNN
- red de Levenberg-Marquardt backpropagation neural (LMBPNN).

Además, se comparan tres variaciones diferentes del análisis discriminante: el análisis discriminante lineal (LDA) utilizando la distancia euclidiana (ELDA) y la distancia de Mahalanobis (MLDA), y el análisis discriminante cuadrático (QDA). Sobre la base de estos estudios, se presenta una metodología innovadora de red neuronal *de caos. El tamaño del conjunto de datos de entrenamiento varía de 20 a 50 EEG (en incrementos de 10). La máxima precisión de clasificación se encontró cuando el tamaño del entrenamiento es 20 EEG para los tres clasificadores (ELDA, MLDA y QDA).

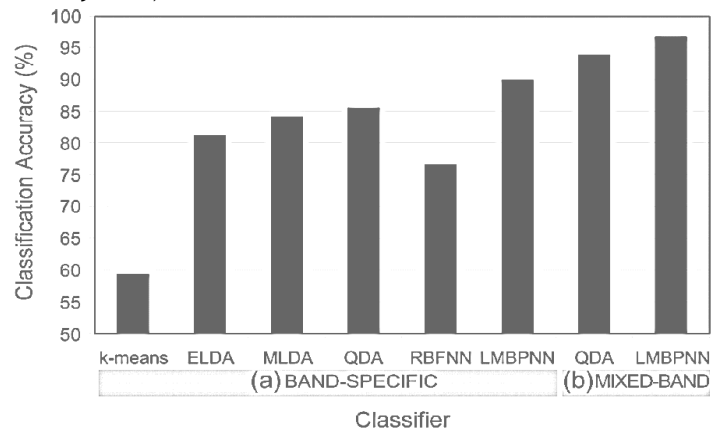


Fig.14 diagrama porcentual del rendimiento del clasificador seleccionado (Tomado de Mixed-Band Wavelet-Chaos-Neural Network Methodology for Epilepsy and Epileptic Seizure Detection).

Los resultados del análisis extenso de Plomo de banda específica a la conclusión de que QDA y LMBPNN ha proporcionado las dos precisiones de clasificación más alta promedio utilizando QDA y LMBPNN son en su orden de

93,8% (con una desviación estándar de 1,0) y 96,7% (con una desviación estándar de 2,9), respectivamente.

Por otra parte, ambas ampliaciones tienen pequeñas desviaciones estándar utilizando diversas combinaciones de conjuntos de datos de entrenamiento / prueba. Siendo entonces el clasificador LMBPNN el de mayor precisión que cualquiera de los otros métodos de clasificación investigados fig 14. Las combinaciones juiciosas de parámetros y ampliaciones pueden discriminar con precisión entre los tres tipos de EEG resultando en una mayor precisión de los sistemas de detección de la epilepsia y convulsiones en tiempo real para ser explorado en futuros trabajos.

Se descubrió que el espacio de características de banda mixta que comprende los siguientes nueve parámetros produjo las precisiones de clasificación más altas: ETS calculada a partir de las bandas limitadas de EEG y alfa, beta y gamma; CD calculado a partir de las sub-bandas alfa, beta y gamma; y LLE calculado a partir del EEG de banda limitada y la sub-banda alfa.

El espacio de características de banda mixta de nueve parámetros fue denotado por:

$$[S_D, LLE, \alpha S_D, \alpha CD, \alpha LLE, \beta S_D, \beta CD, \gamma S_D, \gamma CD].$$

Fig.15 notación de parámetros de análisis de características

En esta notación, los parámetros STD, CD y LLE están representados por los vectores (de tamaño 3K, el número total de EEG en los tres grupos) sd, cd y lle, respectivamente.

ANÁLISIS MEJORADO EN LOS COMPONENTES PRINCIPALES DE COSENO BASE RADIAL Y RED NEURONAL PARA LA DETECCIÓN ROBUSTA DE EPILEPSIA Y CONVULSIONES

Los autores Samanwoy Ghosh-Dastidar, Hojjat Adeli*, Member, IEEE, and Nahid Dadmehr; basan su estudio en un artículo previamente estudiado de 2007 Metodología mixta de red Wavelet-Caos-neural para la detección de epilepsias y ataques epilépticos la población será entonces la misma y bajo las mismas condiciones “ver artículo Metodología mixta de red Wavelet-Caos-neural para la detección de epilepsias y ataques epilépticos” combinándola con nueve características o parámetros pre-establecidos en ese documento a saber: ETS calculada a partir de las bandas limitadas de EEG y alfa, beta y

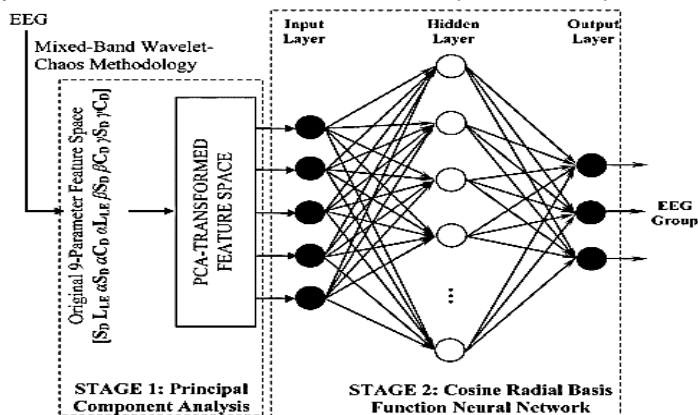


Fig.16 Descripción general de la metodología de red wavelet-caos-neural para el problema de clasificación de EEG de tres clases y la arquitectura

del clasificador RBFNN de coseno mejorado de PCA. (Tomado de “Principal Component Analysis Enhanced Cosine Radial Basis Function Neural Network for Robust Epilepsy and Seizure Detection”).

gamma; CD calculado a partir de las sub-bandas alfa, beta y gamma; y LLE calculado a partir del EEG de banda limitada y la sub-banda alfa. A partir de esto se presenta un nuevo clasificador en dos fases análisis de componentes principales (CPA) y en la segunda fase el nuevo coseno RBFNN mejorado con PCA fig. 16.

Para el aprendizaje supervisado, el conjunto de datos de entrada disponible indicado por una matriz F de dimensión 3Kx9 se divide en los conjuntos de entrada de entrenamiento Fr y entrada de prueba Ft. La entrada de entrenamiento consiste en instancias de entrenamiento de los EEG disponibles donde cada instancia está representada por las nueve características mencionadas anteriormente. El número de instancias de entrenamiento, k, se llama tamaño de entrenamiento. Se selecciona un número igual de EEG K / 3 de cada grupo para entrenar la red neuronal. Por lo tanto, las entradas de entrenamiento y prueba son matrices de tamaño kx9 (dimensiones de Fr) y (3K-k) x 9 (dimensiones de Ft), respectivamente.

No.	Classifier	Output Encoding Scheme 1	Output Encoding Scheme 2
1	RBF+Euc	92.1 (2.5)	95.1 (1.7)
2	RBF+Euc+PCA	92.1 (2.4)	95.1 (1.6)
3	RBF+Cos	90.9 (2.3)	95.7 (1.6)
4	RBF+Cos+PCA	90.5 (2.3)	95.8 (1.6)
5	TBF+Euc	92.8 (1.8)	95.7 (1.6)
6	TBF+Euc+PCA	92.8 (2.0)	95.6 (1.6)
7	TBF+Cos	93.0 (2.1)	96.2 (1.5)
8	TBF+Cos+PCA	92.8 (2.1)	96.6 (1.4)
9	LMBPNN	96.7 (2.9)	89.9 (4.0)

Tabla 4. Algoritmos en comparación con el utilizado en este trabajo en negrita. Tomado de Principal Component Analysis-Enhanced Cosine Radial Basis Function Neural Network for Robust Epilepsy and Seizure Detection.

La entrada de entrenamiento FR se somete a PCA para determinar los ejes del nuevo espacio de entrada reorientado. Los vectores propios correspondientes a los valores propios más bajos se descartan. Los n vectores propios restantes están dispuestos en forma de columna en el orden de valores propios decrecientes para formar la matriz de vectores propios 9xn. Después de PCA, las entradas de entrenamiento y prueba (que constan de nueve características) se transforman en el nuevo espacio de entrada usando:

$$Fr_x = Fr X E \text{ y } Ft_x = Ft X E \quad (6)$$

Los conjuntos de datos de entrada de prueba de entrenamiento transformados Frx y Ftx consisten en n características (correspondientes a vectores propios seleccionados) y, por lo tanto, son matrices de tamaño kXn y (3K-k) Xn, respectivamente. Dado que es más pequeño que el número original de características (es decir, 9), Frx y Ftx son de menor tamaño en comparación con Fr y Ft, respectivamente.

El clasificador RBFNN generalmente consta de una capa oculta además de las capas de entrada y salida. La capa de entrada consta de nodos correspondientes a las características transformadas después de realizar la PCA. La capa oculta puede tener un máximo de nodos, igual al número de instancias de entrenamiento. Emplear una cantidad tan grande de nodos es computacionalmente costoso, pero permite que la red sea entrenada sin error de convergencia de entrenamiento. En muchos casos, al emplear un número menor de nodos, se obtienen resultados suficientemente precisos.

Por lo tanto, el entrenamiento se inicia con un pequeño número de nodos y se repite con un número cada vez mayor de nodos hasta que se logre la convergencia de entrenamiento deseada.

El número de nodos en la capa de salida depende del esquema de codificación de salida que se verá a continuación así:

Esquema de codificación de salida

Se investigan dos esquemas de codificación de salida. En el esquema 1, solo hay un nodo de salida único que produce uno de los tres valores -1, 0 y 1, que representa los tres grupos de señales EEG, respectivamente [10]. El segundo esquema emplea tres nodos de salida correspondientes a los tres grupos EEG. El nodo devuelve una salida de 1 si el EEG pertenece al grupo correspondiente y cero en caso contrario. Por lo tanto, las tres clasificaciones correctas se codifican como {1, 0, 0}, {0, 1, 0} o {0, 0, 1}.

La precisión de la clasificación es comparable al clasificador LMBPNN, pero la sensibilidad a la elección de los datos de entrenamiento se reduce a la mitad. Los neurólogos practicantes tienen la mayor dificultad para diferenciar entre los EEG interictales y normales. Para el diagnóstico de epilepsia, cuando solo se consideran los EEG normales e interictales, la precisión de clasificación del modelo propuesto es del 99,3%. Esta estadística es especialmente notable porque incluso los neurólogos más entrenados no parecen ser capaces de detectar EEG interictales más del 80% de las veces.

UN NUEVO ALGORITMO BASADO EN WAVELET PARA LA DETECCIÓN DE ESPIGAS Y ONDAS EN LA EPILEPSIA AUSENTE (SWD)

Los autores Petros Xanthopoulos, Steffen Rebennack, Chang-Chia Liu, Jicong Zhang, Gregory L. Holme, Basim M. Uthman, Panos M. Pardalos pretende con este documento generar un algoritmo que sea capaz de detectar los SWD y rechazar artefactos y épocas falsas.

Seis pacientes entre los 13 años de edad fueron incluidos en este estudio; dos libres de ataques, con un tiempo total de grabación de 26 horas, cuatro de ellos experimentando más de 100 ataques dentro de 14.5 horas del total de grabaciones. Las grabaciones se realizaron utilizando un dispositivo portátil de grabación SleepMed de 19 electrodos y 16 canales y una frecuencia de muestreo de 200 Hz para cada canal.

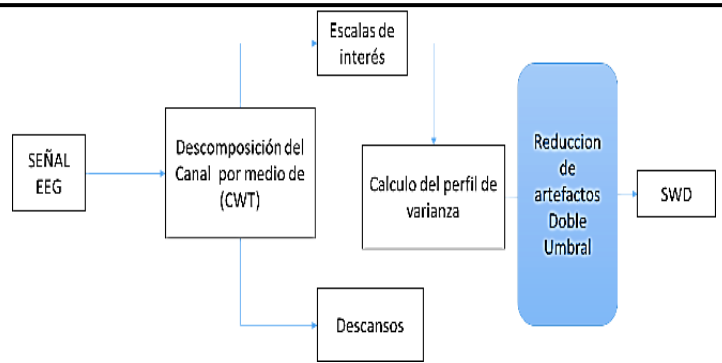


Fig17. método propuesto por los autores. (Autoría propia).

Lo que permitió a los pacientes moverse libremente en su casa el algoritmo detectó solo un hallazgo FP en los primeros pacientes libres de crisis y 148 de 186 épocas continuas ininterrumpidas de pico y descarga de onda (SWD) de 3Hz en el resto de los pacientes. Del total de 38 épocas de SWD perdidas, 28 fueron ≤ 2.1 segundos de duración. Las épocas restantes incluyeron SWD interrumpidos de 3Hz. Los puntos de datos fueron recolectados a una frecuencia de muestreo de 200 Hz para cada canal. “Una incautación de ausencia típica, para los seres humanos, se caracteriza por descargas generalizadas y bilateralmente sincronizadas de picos y ondas de 3Hz (SWD) con 5 a 20 segundos de duración (Niedermeyer, Ernst; Lopes Da Silva; 1983)”.

Para este documento La descomposición de wavelets tiene profundas ventajas, porque se puede aumentar la resolución de frecuencia en la banda de frecuencia de interés (en este caso, la banda delta ~ 3 Hz) mientras se mantiene la misma resolución de tiempo. Por esto se usa la variante CWT. Es muy especialmente útil en la detección de ataques de ausencia porque estos picos y descargas de ondas (SWD) están restringidos a una ventana de frecuencia estrecha de 2.5-4.5 Hz.

Posteriormente se calcula el perfil para cada canal utilizando una ventana móvil de muestras de longitud k . Usando $k = 200$ muestras que corresponden a 1 seg. Para cada canal filtrado de wavelet que puede verse como una serie temporal de N puntos de muestra $X = [x_1, x_2, \dots, x_N]$, calculamos las varianzas de muestra (V_i) que corresponden a los conjuntos $w(k)_i = \{x_j \in X \mid j \geq i, j < i + k\}$ para $i = 1, \dots, k$ y calculamos las varianzas $V(k)_i = \text{Var}(w_i)$ con este cálculo promedio se agregan los perfiles de varianza para todos los canales.

Para evitar detectar artefactos que aparecen en la banda de frecuencia de interés, utiliza doble umbral. Primero realizamos un umbral con un umbral más alto (definido por el valor de variación máxima durante una convulsión) para detectar la convulsión y luego, para cada convulsión detectada, realizamos una búsqueda local para el inicio de la convulsión y la compensación con un umbral más bajo. Este segundo umbral se puede estimar a partir del valor de variación entre el inicio y el desplazamiento para algunos ejemplos conocidos. Observamos que en el entorno MATLAB el algoritmo necesita 163 segundos para procesar y almacenar 30 minutos de grabaciones.

Los experimentos se realizaron en una computadora portátil con Pentium duo 2.00GHz con 1Gb de memoria.

El la eficacia del algoritmo para detectar épocas cortas está en los parámetros de varianza donde: si la ventana se vuelve demasiado pequeña, el algoritmo será más sensible a los pequeños cambios, pero también será más fácil detectar artefactos lentos cortos como épocas SWD. Por otro lado, si la ventana de varianza se vuelve demasiado larga (en muestras) es fácil pasar por alto épocas más cortas que la longitud de la ventana. Por lo tanto, el algoritmo necesita que clasifique automáticamente las espigas en los eventos SWD cortos.

DETECCIÓN DE ATAQUES EPILÉPTICOS BASADOS EN SEÑALES DE EEG

En el documento el autor ye yuan hace uso de dimensión de incrustación para la discriminación entre ataques ictales e interictales observando las fluctuaciones en el ancho de banda. Se obtuvieron dos grupos de señales de EEG, de un paciente epiléptico con una tarjeta de adquisición de datos de 16 canales de acuerdo con el sistema de canal internacional estándar. La frecuencia de muestreo fue de 200Hz con un tiempo de muestreo de 80 segundos, el primer grupo consta de señales EEG en estado interictal y el grupo dos de señales EEGs en estado ictal inducida. La frecuencia de muestreo fue de 200Hz con un tiempo de muestreo de 80 segundos, Entre los 16 pares disponibles de conjuntos de datos de EEG normales y epilépticos, se usan 8 pares para el entrenamiento y el resto para probar el rendimiento.




Fig17. Metodología propuesta para detección epiléptica basada en señales EEG (elaboración propia).

El método de Caos se aplica para calcular la dimensión de incrustación de Si ($i = 1, 2, \dots, 16$), 16 piezas de líneas de puntos para series temporales de EEG normales y 16 piezas de líneas de trazos para series temporales de EEG epiléptico en el cual la dimensión en la series de tiempo no es constante y fluctúan para ambos grupos en una banda, además de presentar fluctuación en su ancho de banda donde las líneas construidas por series temporales ictales son mucho mayores que las producidas interictales normales. por lo tanto, la diferencia de la dimensión de incrustación entre las series de tiempo de EEG normales y epilépticas se utiliza como la característica de entrada única de la red neuronal artificial para la automatización detección de epilepsia.

los valores de dimensión de incrustación se calculan para señales de EEG normales y epilépticas, y se alimentan como característica de entrada a las SVM. Entre los 16 pares disponibles de conjuntos de datos de EEG normales y epilépticos el algoritmo de entrenamiento SVM construye un modelo que predice si un nuevo ejemplo cae en una categoría u otra.

Por último, se evalúa la precisión general del algoritmo que arroja como resultado de rendimiento una precisión

del 100% para series temporales interictales normales e inferior al 100% para series temporales ictales.

resultados obtenidos por SVM se comparan con resultados obtenidos por Red neuronal probabilística (PNN). Los resultados muestran que la precisión general de hasta el 100% se puede lograr con ambos métodos; sin embargo, para la misma precisión, el experimento de SVM necesita menos funciones de entrada que PNN.

TERCERA ETAPA (2011-2015) SELECCIÓN DE CARACTERÍSTICAS PARA LA DETECCIÓN AUTOMÁTICA DE RÁFAGAS EN EL ELECTROENCEFALOGRAMA NEONATAL.

Clasificación de los patrones de alta energía con actividad de picos y ondas entremezclados para los ciclos de ráfagas de características como la relación entre la energía no lineal media y la relación entre la tensión media absoluta para la detección de actividad de onda de ráfaga.

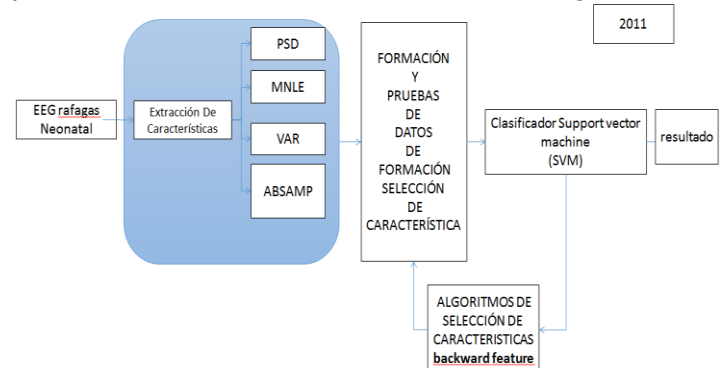


Fig.18 metodología con extracción de características iterativo. (Elaboración propia).

Este estudio se realizó sobre datos de EEG adquiridos de 12 recién nacidos a término entre 37 y 42 semanas completas. Todas las grabaciones se realizaron en la Unidad de cuidados intensivos neonatales del Departamento de Neonatología del Hospital SSKM, Calcuta, India, utilizando el sistema NicOne 5.3 EEG. Durante la grabación de datos, se utilizó el montaje bipolar con seis electrodos, de acuerdo con el estándar internacional 10-20. En los recién nacidos, las convulsiones se pueden identificar principalmente en las regiones cerebrales central (C), temporal (T) y parietal (P) de los recién nacidos. Por lo tanto, el montaje del electrodo utilizado para el registro consistió en seis canales bipolares: 1) T4-P4, 2) P4-C4, 3) C4-T4, 4) T3-P3, 5) P3-C3, y 6) C3-T3. Antes de grabar, los sitios de los electrodos se limpiaron y se frotaron hasta que la impedancia de la piel se redujo a menos de 5 k. Esto garantiza el rechazo de señales de modo común, como la interferencia de la red eléctrica de 50 Hz. De los 12 archivos de datos registrados de 12 recién nacidos a término, tres archivos tienen una duración inferior a 15 minutos; Cuatro archivos de datos tienen una duración entre 15 min y 1 h; Cinco archivos de datos tienen una duración de 1 a 5 h. Todas las señales EEG adquiridas tienen presencia de patrones de ráfaga claros, a veces asociados con patrones de supresión claros, lo que confirma la existencia de actividad de ataques. De la grabación original de datos, siete archivos tuvieron una frecuencia de muestreo de 125 Hz; Los archivos restantes tenían una tasa de muestreo de 2000 Hz.

El procesamiento y visualización de EEG se realiza sin ningún tipo de muestreo. La variación en la tasa de muestreo durante la adquisición de datos se debe a los ajustes de grabación. Pero no afecta la detección de artefactos ni ningún otro método de procesamiento de EEG.

Así que no se realiza ninguna operación de muestreo descendente. Como los métodos convencionales de análisis de señales de EEG se basan en la información extraída de los componentes de frecuencia por encima de 0,5 Hz y los artefactos de sudor comprometen las grabaciones en las frecuencias más bajas (<0,5 Hz), cada segmento de datos de EEG se filtró entre 0,5 y 35 Hz. El paso de la banda de paso del filtro se estableció en 0.1 Hz. Para el filtrado, la atenuación de la banda de parada y la ondulación de la banda de paso se establecieron en 80 dB y 0.1 dB, respectivamente. Se usó un filtro FIR de la ventana de Kaiser para el filtrado. Para cumplir con el paso de la banda de paso y las especificaciones de ondulación, el orden del filtro se estableció en 101. El diseño y la implementación del filtro junto con la especificación del orden del filtro se realizaron utilizando la caja de herramientas de procesamiento de señales de MATLAB 7.8.0. Después del preprocesamiento de las grabaciones continuas de EEG, cada uno de los archivos de datos fue marcado visualmente por tres médicos de forma independiente. Para la marcación de eventos, se utilizaron los mismos ajustes de pantalla para todos los médicos: filtrado en el rango de frecuencia de 0.5-35 Hz, sensibilidad de 5 V / mm y tiempo base de 15 mm / s. Los médicos marcaron la ruptura y los segmentos normales de EEG; además, algunos segmentos se marcaron como desconocidos y no se concluyeron correctamente como pertenecientes a ráfagas, artefactos, normal o cualquier otro patrón de convulsiones típico. Se marca la duración mínima de la ráfaga como 1s. El valor de la duración máxima de la ráfaga no tiene tal restricción predefinida, pero algunos trabajos ponen el límite máximo general en 10s. Esta restricción para la duración máxima de la ráfaga se utiliza en el conjunto de datos. (Tomado de Sanei y Chambers, 2007) El estudio actual modela la transición de los valores de las características de ráfaga a EEG de fondo o viceversa, para la discriminación entre los patrones de EEG de ráfaga y de fondo. Se calcula la relación de características como la densidad espectral de potencia (PSD), la energía no lineal media (MNLE), la varianza (VAR) y la suma de la tensión absoluta entre un segmento (ABSAMP) de EEG y el EEG de fondo correspondiente. Estos valores no se comparan con ningún umbral estático predefinido, sino que se proporcionan como entradas a un clasificador de máquina de vectores de soporte (SVM) para una mayor generalización y adaptabilidad del algoritmo.

Dado que existen variaciones entre los revisores en su juicio de inicio y terminación de segmento de ráfaga, la ráfaga final en el tiempo establecido (finbot) tomado se toma como el máximo de las marcas de tiempo de inicio individuales, mientras que la hora de finalización de ráfaga final (finbtt) se toma Como mínimo de las marcas de tiempo individuales. El intervalo entre estos dos valores finales de marca de tiempo se trata como el intervalo de

ráfaga. Los patrones que rodean el período de ráfaga marcado constituyen el EEG de fondo.

Se muestra un esquema del intervalo de ráfaga marcado y el límite EEG de fondo. Cualquier valor de característica particular para los segmentos normales o de ráfaga se calcula utilizando la parte media del segmento de datos extraídos.




Fig. 19. Ejemplo de un segmento de ráfaga marcado de 2.2 s de longitud, precedido por 3s y seguido por 2 s de información de EEG de fondo. Las líneas verticales profundas corresponden al intervalo de 1 s; líneas verticales punteadas significan un intervalo de 0.2 s (tomado de "Feature Selection for Automatic Burst Detection in Neonatal Electroencephalogram").

Los valores de las características correspondientes al EEG de fondo se calculan considerando tanto los 3s iniciales como los 2s finales; así, el total de (3+2) =5s de la señal se trata fig18.marcado límite del EEG.

Este estudio tiene tres métodos de selección de características diferentes se experimentaron-1) generación característica exhaustiva subconjunto, 2) reducción de la función de atrás, y 3) análisis de componentes principales. Los valores de la característica junto con la etiqueta constituyen el conjunto de datos de entrenamiento y prueba.

Features Number	Features Name
1	Higuchi fractal dimension(HFD)in burs/normal segment
2	Ratio between MNLE within burst /normal segment EEG And background segment EEG
3	Mean of absolute voltage value in burst/normal segment
4	Ratio between mean value of absolute voltage within burst /normal segment EEG and background segment EEG
5	MNLE within burst /normal segment
6	Mean of PSD within burst /normal segment
7	Ratio between mean value of PSD within burst /normal segment EEG and background segment EEG
8	3Hz power in burst /normal segment
9	10Hz power in burst /normal segment
10	Variance in burst /normal segment
11	Ratio between Variance within burst /normal segment EEG and background segment EEG
12	Kurtosis in burst /normal segment
13	95% Spectral EdgeFrequency (SEF95) in burst /normal segment
14	Shannon Entropy in burst /normal segment
15	Skewness in burst /normal segment

Tabla.4. Características para clasificar entre ráfagas y segmentos normales de datos de EEG (características que incluyen ráfaga / normal a la función de segmento de antecedentes (Tomado de "Feature Selection for Automatic Burst Detection in Neonatal Electroencephalogram").

La información de relación propuesta de (MNLE), (PSD), (VAR) entre los segmentos normales o de ráfaga y los segmentos de EEG de fondo, respectivamente. Estos valores de características tienen la máxima precisión de clasificación. Las características 3, 5, 6 y 10 tratan con valores absolutos de las características respectivas calculadas en segmentos de EEG de ráfaga o normales. Resto de las características fueron reportadas en trabajos anteriores fig23.

La (PSD) de 3 y 10 Hz, se mide calculando primero la PSD del segmento actual utilizando una transformada rápida de Fourier (FFT). Para los datos de entrada que tienen una frecuencia de muestreo de 125 y 2000 Hz, la longitud de la ventana FFT aplicada es 128 y 2048, respectivamente. Se utiliza una ventana de Hamming durante el cálculo de FFT. La potencia a frecuencias de 3 y 10 Hz se deriva utilizando el espectro de potencia en aquellas frecuencias rodeadas por un ancho de banda de 1 Hz. Entonces, el espectro de potencia dentro de 2.5-3.5 Hz y 9.5-10.5 Hz se usa para calcular la potencia de 3 y 10 Hz, respectivamente.

Clasificador:

Para probar el rendimiento de la clasificación con el conjunto de características mencionado anteriormente, se utiliza un esquema de clasificación binaria que utiliza la máquina de vectores de soporte (SVM). La salida del clasificador es binaria: 0 significa segmento EEG normal y 1 indica segmentos EEG de ráfaga.

SVM asigna datos de entrada a un espacio de características de dimensiones superiores a través de algún método de asignación no lineal seleccionado o núcleo. Luego se construye una superficie de decisión lineal en este espacio de características de alta dimensión.

La función del núcleo para un determinado problema depende de los datos específicos. Aquí, la función del núcleo de la función de base radial (RBF) se selecciona como el método de mapeo no lineal. Para la evaluación del rendimiento de la clasificación SVM, los valores de sensibilidad y especificidad (como se definen a continuación) se utilizan como métricas de rendimiento, ver ecuación (3), (4), (5).

Requiere más pruebas con un nuevo conjunto de datos continuos registrados durante mucho tiempo con los comentarios apropiados de los expertos para finalmente juzgar la precisión general del sistema de clasificación basado en características propuesto.

DESARROLLO DE DETECCIÓN EPILÉPTICA BASADA EN EEG UTILIZANDO RED NEURONAL ARTIFICIAL

Este proyecto propuso desarrollar un sistema que pueda detectar la epilepsia basada en la señal EEG utilizando una red neuronal artificial. La Transformación discreta de Wavelet (DWT) y la Transformada rápida de Fourier (FFT) se aplicaron como métodos de extracción de características. Estas características se configuran como entrada a la red neuronal de avance con algoritmo de entrenamiento de propagación hacia atrás para obtener la precisión de clasificación.

Para la extracción de características se seleccionaron cinco características para DWT y tres para (FFT) que sirven de entrada a la clasificación ANN.

Características para DWT:

- Máximo de los coeficientes wavelet entre cinco sub-bandas
- Mínimo de los coeficientes wavelet entre cinco sub-bandas
- Media de los coeficientes wavelet entre cinco sub-bandas.
- Desviación estándar de los coeficientes Wavelet entre cinco sub-bandas
- Potencia sumatoria de los coeficientes wavelet entre cinco sub-bandas

Características para FFT:

- Media de la densidad del espectro de potencia.
- Amplitud máxima de la densidad del espectro de potencia.
- Amplitud mínima de la densidad del espectro de potencia.

Las épocas tomadas son 2500, 5000, 7000, 8000 y 10000 y este paso fue entrenado tres veces para cada época. Se tomó el valor promedio de precisión para la repetición de cada época. Además, los números de neuronas ocultas también se han probado con 10, 20, 30, 40 y 50. Esta red se entrena utilizando la red neuronal de alimentación directa con algoritmo de retro propagación. Para el entrenamiento se muestran

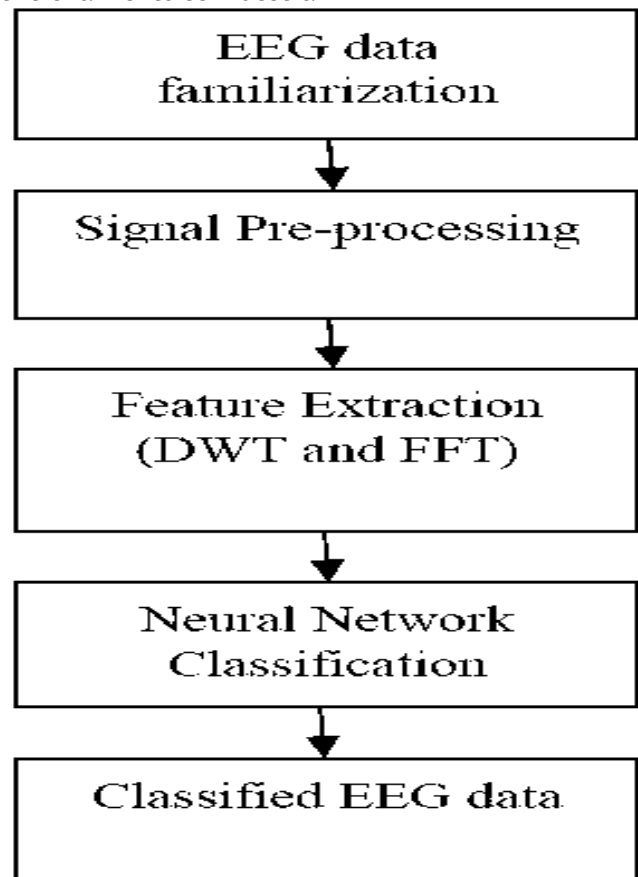


Fig.20 metodología (tomado de Development of EEG-based Epileptic Detection using Artificial Neural Network.2012).

resultados de precisión y tiempo frente a las épocas tomadas donde el tiempo es directamente proporcional al número de épocas seleccionadas a mayor número de épocas seleccionadas mayor es el tiempo de entrenamiento, por lo tanto, el sistema se vuelve lento para entrenar la red. Los resultados de precisión varían de igual manera al número de épocas tomadas, esto es a mayor número de épocas seleccionadas los porcentajes de precisión aumentan, no obstante, la combinación de características DWT y FFT muestra una mejor precisión alcanzando su punto de equilibrio máximo para el entrenamiento en 7000 épocas en un 98.889%.

DETECCIÓN DE ATAQUES Y EPILEPSIA UTILIZANDO ESTADÍSTICAS DE ORDEN SUPERIOR EN EL DOMINIO DE EMD

S. M. Shafiul Alam and M. I. H. Bhuiyan Implementan un algoritmo de descomposición de modo empírico (EMD) como método de identificación de máximos y mínimos de onda, es un proceso de extracción de patrones oscilatorios modulados en amplitud y frecuencia a partir de datos de una serie de tiempo. Estos patrones, llamados FMI, se derivan de la base obtenida de los datos propios.

En este documento, las estadísticas de orden superior, como la varianza, la asimetría y la curtosis, se utilizan para clasificar las señales de EEG en el dominio de EMD. La base de datos consta de 500 segmentos de EEG y está disponible en línea “como se citó anteriormente en metodología mixta de red wavelet-caos-neural para la detección de epilepsias y ataques epilépticos. Samanwoy et al., 2007. (Andrzejak 2001)”

La razón para usar la base de datos según autores es su disponibilidad en el dominio público y su uso generalizado en la literatura. Para este artículo los electrodos del cuero cabelludo que contienen fuertes artefactos de movimiento ocular no se consideran en la construcción de estos dos conjuntos.

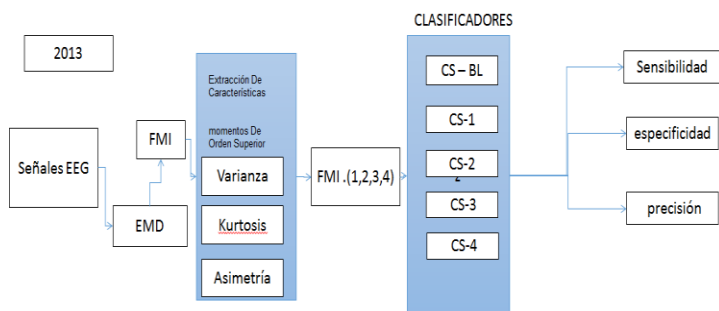


Fig.21. cuadro de características estudiadas comprende 5 clasificadores y 3 extractores de características (elaboración propia).

Se seleccionan cinco pacientes que han logrado un control completo de las convulsiones después de la resección de una de las formaciones del hipocampo.

Dado que el rango de frecuencia de una señal EEG abarca más de 0-60 Hz [6], las frecuencias superiores a 60 Hz se consideran ruido y se descartan al pasar cada señal a través de un filtro Butterworth de sexto orden que tiene una frecuencia de corte de 60 Hz. El conjunto E contiene señales correspondientes a ataque ictal, grabados con todos los electrodos.

Estos sitios de resección se diagnostican, así como zona epileptogénica. Los electrodos intracraneales que contienen actividad patológica (se refiere a las respuestas neuronales relacionadas con el trastorno emocional) no se consideran en los Conjuntos C, D y E.

Las características recopiladas de los EEG de BL se utilizan para diseñar el clasificador CS-BL, donde CS y BL representan clasificador y límite de banda, respectivamente. De la misma manera, los otros cuatro clasificadores, CS-1, CS-2, CS-3 y CS-4 se desarrollan utilizando los vectores de características obtenidos de los IMF, 1, 2, 3 y 4, respectivamente.

Para los cinco conjuntos de registros de EEG descritos anteriormente, se consideran cinco casos diferentes de problemas de clasificación. Los casos se eligen en función de su relevancia clínica y se utilizan en diversos artículos de la literatura. En el caso I, los registros de EEG se clasifican en tres categorías. Los segmentos de EEG de los Conjuntos A y B se etiquetan como clase sana. Los conjuntos C y D se agrupan en la clase interictal y el conjunto E en la clase de incautación. En el caso II, los conjuntos A, D y E se clasifican en clases sanas, interictales y convulsiones, respectivamente.

Los casos I y II están relacionados con la discriminación de personas sanas frente a los pacientes con epilepsia y con la detección de convulsiones. En el caso III, las señales de los Conjuntos A y E se clasifican en clases sanas y de convulsiones, respectivamente. En el caso IV, los conjuntos A, B, C y D se agrupan para formar la clase de no incautación, mientras que el conjunto E es la clase de incautación.

Los casos III y IV corresponden a la detección de convulsiones y, además, pueden estar relacionados con la discriminación de los EEG de superficie de los intracraneales, ya que los Conjuntos (A, B) y (C, D, E) se adquieren de los electrodos de superficie e intracraneal. Respectivamente. En el Caso V, los Conjuntos D y el Conjunto E se clasifican en las clases interictal y de convulsiones, respectivamente, y pueden estar relacionados con la detección de la aparición de convulsiones en un sistema automático de detección de convulsiones. Las frecuencias medias de la función de modo intrínseco (IMF) obtenidas por el EMD de una señal de EEG se muestran efectivas para discriminar los períodos ictales y no ictales. Para fines de análisis, cada segmento EEG se descompone usando EMD en nueve IMF.

En este trabajo, los momentos de orden superior que incluyen la varianza, curtosis y asimetría, extraído de las IMF de las señales de EEG se usan como características en una ANN para clasificar las señales de EEG, en otras palabras las características se extraen de los IMF utilizando el criterio de Mann-Whitney Test y Lambda of Wilks y se usan en un analizador lineal discriminante para clasificar las señales de EEG aunque Para fines de comparación, se desarrollan cinco clasificadores independientes.

En el caso I, la precisión es del 80% en comparación con el 97.72% de precisión. Esto se debe principalmente a la clasificación errónea de los grupos sanos (A y B) en los epilépticos (C, D y E).

De los valores de sensibilidad y especificidad correspondientes, está claro que los Conjuntos C, D y E están discriminados con precisión de los Conjuntos A y B. Como los conjuntos (A, B) representan señales de pacientes sanos y el neurólogo puede descartar falsas alarmas, se puede esperar que el efecto clínico de este error de clasificación sea mucho menor en comparación con la clasificación errónea de los Conjuntos C, D y E. El TFA calcula la correlación de un registro EEG de 23,6 s con una función de base particular en un tiempo-frecuencia.

El rendimiento del método propuesto se estudia utilizando medidas estándar como sensibilidad (Sen), especificidad (Spec), y precisión (Acc), expresada en (ver (3), (4), (5)).

Case	Method	Feature and classifier	Number of features used	Accuracy (%)
I {A,B}, {C,D}, F	Tzallas et al.[12] (2007)	Fractional energy from TFA, ANN	40	97.72
	Proposed	EMD, higher order moments, ANN	3	80
II A, D, E	Tzallas et al.[12] (2007)	TFA, ANN	13	99.28
	Tzallas et al.[13] (2009)	Reduced Interference Dist., ANN	16	100
	Liang et al.[8] (2010)	TFA, AE, PCA, RBF SVM	16	98.67
	Proposed	EMD, higher order moments, ANN	3	100
III A, E	Tzallas et al. [13] (2009)	Reduced Interference Dist., ANN	16	100
	Bedeeuzzaman et al. [10] (2010)	Higher order statistics, Linear classifier	4	97.75
	Fathima et al.[11] (2011)	Higher order statistics, Linear classifier	3	96.9
	Proposed	EMD, higher order moments, ANN	3	100
IV {A,B,C,D}, E	Tzallas et al.[12] (2007)	Smoothed pseudo-Wigner-Ville dist., ANN	16	97.73
	Liang et al.[8] (2010)	TFA, AE, PCA, RBF SVM	16	98.51
	Proposed	EMD, higher order moments, ANN	3	100
V D, E	Liang et al [8] (2010)	TFA, AE, PCA, RBF SVM	16	98.74
	Proposed	EMD, higher order moments, ANN	3	100

Tabla 5. Comparación de efectividad con otros métodos ficha proveniente del artículo. (tomado de "Detection of Seizure and Epilepsy Using Higher Order Statistics in the EMD Domain").

DETECCIÓN DE ATAQUES EPILÉPTICOS DE AUSENCIA UTILIZANDO LA MÁQUINA DE VECTORES DE SOPORTE

El objetivo de este trabajo para los autores C.F. Reyes, T. J. Contreras, B. Tovar, and L.I. Garay es hacer uso de MVS para la detección de crisis de ausencia epileptogénica.

Los EEG se obtuvieron de una paciente de 7 años de edad previamente diagnosticada con epilepsia de ausencia a una resolución de 16 bits y una frecuencia de muestreo de 200Hz, con una duración de 37 minutos y 51 segundos, se dividieron en segmentos de 1 segundo (200 muestras). Las señales se dividieron en sub-bandas estándares (Beta, Alpha, Theta, Delta). Usando un filtrado de paso de banda Chebyshev con algoritmo Parks-MacLellan con una ondulación de 0.05 en la zona de paso de banda, una atenuación de banda de parada de 0.0001 y un factor de

densidad de 20 y su contenido energético se obtuvo utilizando la Transformada rápida de Fourier.

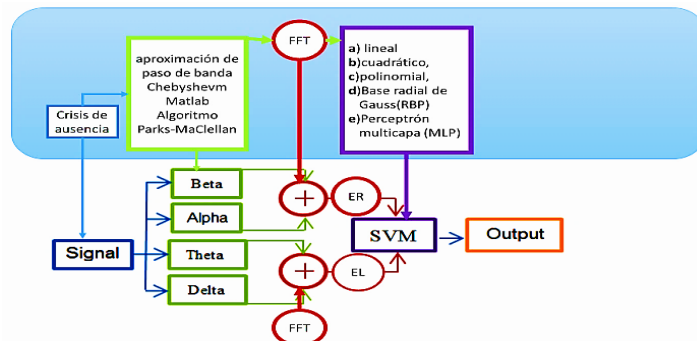


Fig.22 metodología propuesta tomado y modificado de Detection of Absence Epileptic Seizures Using Support Vector Machine. 2013.

A partir de ese contenido energético, se crean dos parámetros en frecuencia, para el primero se adicionan señales de ondas lentas theta y delta con un rango de frecuencia de 0.5 Hz a 8.5Hz (EL), para el segundo se adicionan señales de ondas rápidas con rango 8,5 Hz - 70 Hz (ER). De los 16 canales seleccionados se escoge la señal de electrodos C3-P3 como conjunto diferencial de entrenamiento ya que se encuentra en la línea central de la cabeza del cual se espera un comportamiento similar al de los demás canales por ser un ataque generalizado. Por ultimo Se muestra una comparación de cinco núcleos de clasificadores: (lineal, cuadrático, polinomial, RBF y MLP) evaluando su eficiencia para la detección de este evento epiléptico basado en lecturas hechas por EEGs expertos, cada matriz de confusión se realiza calculando los parámetros de eficiencia para SVM usando cada núcleo.

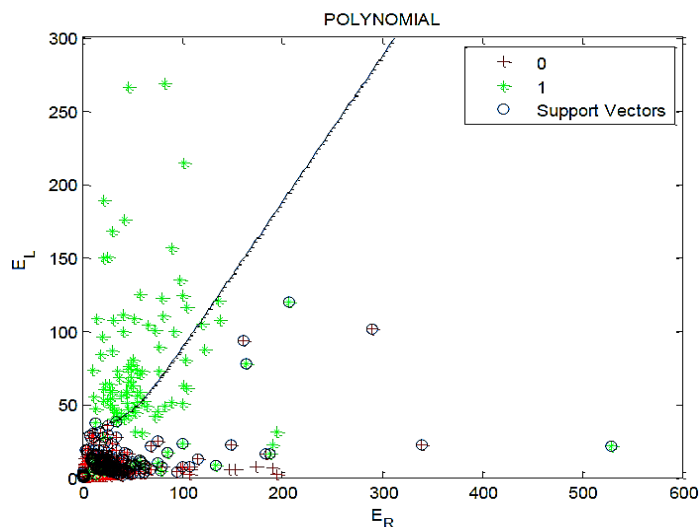


Fig.23 Ejemplo de formación de núcleo polinomial tomado de Detection of Absence Epileptic Seizures Using Support Vector Machine 2013.

Para comparar los datos obtenidos se usaron medidas estándar de evaluación ver ecuación (3), (4), (5). El núcleo con el mejor rendimiento es el cuadrático, con una precisión del 99,43% en este caso específico.

EXTRACCIÓN Y SELECCIÓN Y PUNTOS REDUNDANTES DE CARACTERÍSTICAS DISTINTIVAS DE EEG PARA UNA PREDICCIÓN EFICIENTE DE LAS CRISIS EPILÉPTICAS

Este artículo los autores Ning Wang, Member, and Michael R. Lyu, Fello. Pretende disminuir los ruidos y puntos redundantes mediante la extracción de amplitud y frecuencia recogiendo parámetros distintivos de convulsiones en los EEG.

Los datos se recogen de la base de datos EEG de Freiburg un conjunto de datos de EEG intracraneal disponible para el público, que contiene registros de EEG invasivos de 21 pacientes que padecen epilepsia focal intratable. El conjunto de datos se registró durante un monitoreo invasivo de epilepsia prequirúrgica en el Centro de Epilepsia del Hospital Universitario de Friburgo, Alemania. Los datos de EEG se adquirieron utilizando un sistema EEG de video digital Neurofile NT con 128 canales, una frecuencia de muestreo de 256 Hz y un convertidor de analógico a digital de 16 bits.

Para cada uno de los pacientes, hay dos conjuntos de datos que contienen señales de EEG de las fases ictal e interictal, respectivamente. Para fines de predicción, al menos 50 minutos de los datos preictales se conservaron antes de cada ataque epiléptico. En cuanto a los estados interictales, se proporcionaron aproximadamente 24 horas de grabaciones de EEG sin actividad de incautación.

Al menos 24 horas de grabaciones interictales continuas disponibles en 13 pacientes. Para los pacientes restantes, los datos de EEG invasivo interictal que consisten en menos de 24 horas se juntaron, para terminar con al menos 24 horas de registros interictales por paciente. Para cada paciente, las grabaciones de tres contactos de electrodos focal y tres de contacto extrafocal fueron probados.

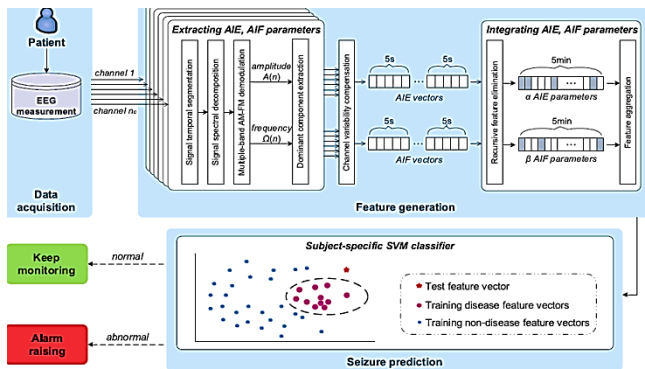


Fig. 24. Metodología del artículo tomado de Extracting and Selecting Distinctive EEG Features for Efficient Epileptic Seizure Prediction 2015.

Para este documento en un comienzo se activa un extractor de características que puede descomponer una señal de EEG de acuerdo con su contenido de frecuencia e identificar las amplitudes más dominantes y las magnitudes de frecuencia en su interior. En esta tarea se emplea extracción en una señal de modulación de frecuencia y amplitud mono-componente (AM - FM) como un ritmo EEG, los dos parámetros determinantes son la amplitud y la frecuencia tomando la primera señal en sub-bandas de 10s de longitud con el modelo multibanda (AM -FM) que caracteriza las señales con el uso de parámetros.

En segundo lugar, se producen dos conjuntos de secuencias características a envolvente instantánea promediada (AIE) y la frecuencia instantánea promediada. Los parámetros (AIF) usando cuatro pasos en su orden: (segmentación de la señal en épocas de 5s; descomposición de señal empleando un banco de filtros (FIR) divide las épocas en 5

K sub-bandas(delta, theta, alfa, beta y gamma); Demodulación multibanda usando un algoritmo de separación de energía propuesto en la aplicación para obtener una secuencia instantánea de envolvente (IE) | A (n) | y frecuencia angular instantánea (IF) Ω (n) una época por otra para cada señal de sub-banda; un suavizado de frecuencia el módulo de selección de características adjunto discriminará y descartará los parámetros menos relevantes de otros en estos componentes extraídos de amplitud a corto plazo en frecuencia.

los vectores se forman mediante la concatenación de conjuntos 5-s AIE y AIF secuencialmente juntos llamados AIEFI. Finalmente, los parámetros restantes constituyen vectores representativos de las características del EEG.

Para examinar la eficacia del marco propuesto, se demuestra experimentalmente que los parámetros producidos de esta manera producen un rendimiento de clasificación preictal / interictal superior y son físicamente significativos para la tarea de predicción de ataques. En este documento, se considera un enfoque de RFE-SVM como filtro para eliminar características ruidosas, así como para aprovechar el poder de discriminación de los clasificadores SVM. La filosofía básica de la eliminación de características recursivas (RFE) es incluir inicialmente todos los puntos característicos sobre un tema específico, y excluir gradualmente los puntos que no contribuyen a discriminar patrones de diferentes clases. Si un parámetro en el conjunto de características actual contribuye lo suficiente como para ser retenido depende de su valor de peso resultante del entrenamiento de un clasificador con el conjunto actual de características. La eliminación de características generalmente progresa gradualmente e incluye pasos de validación cruzada. Para cada paciente, en el proceso de validación cruzada de registro de salida, la evaluación y selección de características realizadas en cada iteración de validación es independiente de las demás. Se retendrá el conjunto de características que produce el mejor rendimiento general entre todas las iteraciones.

Específicamente, se logró un 98,8% de resultados de sensibilidad en los 19 pacientes incluidos en este experimento, donde solo una de las 83 convulsiones en todos los pacientes no fue predicha. Así como las alarmas menos falsas, y dar advertencias lo antes posible para que se tomen medidas urgentes.

El periodo de tiempo durante el cual se supone que ocurre una convulsión se define como período de ocurrencia de las crisis (SOP), pero antes de la SOP se denomina horizonte de predicción de las crisis (SPH) [12]. El SPH puede durar desde unos pocos minutos hasta horas, Una vez que ocurre una convulsión dentro del SOP, la predicción se considera exitosa, de lo contrario, se determina como una falsa alarma.

En una prueba de detección que evalúa a las personas para detectar una enfermedad, cada sujeto que realiza la prueba tiene o no la tiene. El resultado de la prueba podría ser positivo o negativo, lo que indica que el sujeto está enfermo o no está enfermo, respectivamente. Los

resultados de la prueba para cada sujeto en esta configuración pueden ser (spe);(Sen) ;(Acc) :(ver ecuaciones (3), (4), (5)).

Al aplicar el modelo multibanda AM-FM en la señal EEG, dos conjuntos de secuencias características: la envolvente instantánea promediada (AIE) y la frecuencia instantánea promediada (AIF).

La extracción de parámetros AIE y AIF se generan a partir de épocas de 5s sin solapamiento de las cinco sub-bandas EEG. Se toman dos procedimientos de agregación en estos vectores 5-D para adquirir formas de características más distintas y completas. En el primer paso, incorporamos un par de vectores AIE y AIF uno tras otro para formar un vector AIEF, cuya dimensión es, por lo tanto, igual a la suma de los individuales. Para concatenar fragmentos consecutivos de características de EEG secuencialmente en el tiempo para proporcionar un intervalo de decisión más largo, en el segundo paso, buscamos un grado de concatenación adecuado para los vectores AIEF de forma heurística. Para este propósito, los vectores AIEF de 5s de largo se integran temporalmente en las formas vectoriales de 1 min, 2 min y 5 min para probar el rendimiento de la predicción de las convulsiones. El artículo muestra resultados de las falsas alarmas en seis pacientes de estas funciones AIEF recién generadas.

Los resultados registrados en el mismo son de los conjuntos de características de mejor rendimiento entre los conjuntos de parámetros AIE, AIF y AIEFlni. En promedio, la sensibilidad general obtenida en todos los pacientes es del 95,2%, en la que se han pronosticado con éxito 79 de 83 incautaciones en el conjunto de evaluación.

Debido al hecho de que una cantidad significativa de detecciones positivas aisladas resultan ser falsas alarmas, se toma un paso de filtrado de dos en una fila para disminuir los positivos únicos, dejando solo alarmas positivas consecutivas (al menos dos) contabilizadas en los resultados. Terminamos logrando un resultado de especificidad de 0.138 FA por hora con este tipo de características.

La sensibilidad paciente a paciente y el rendimiento de FA / h, así como sus resultados generales, se anotan numéricamente. Se encontró que, en términos de sensibilidad promedio, las características de AIEFref superan al conjunto de características de mejor rendimiento de {AIE, AIF y AIEFlni} con una mejora relativa de 3.78%, mientras que la especificidad general en FA / h se ha mejorado mucho en un 60.9%. Como resultado, el método de extracción de características presentado conduce a una sensibilidad general tan alta como 98.8% y una tasa de falsa alarma tan baja como 0.054 FA / h.

En particular, se terminó con una sensibilidad perfecta (100%) para 18 de los 19 pacientes incluidos en nuestro experimento, solo faltando uno de los 83 ataques implicados en todos los pacientes. El estudio descrito en este documento se distingue de la mayoría de los enfoques actuales de predicción de ataques, que emplean procesos de extracción de características exhaustivas y de alta

dimensión. Por lo tanto, se espera que proporcione nuevas perspectivas en los diagnósticos modernos de enfermedades. Como adición en las tareas de clasificación, mientras que los métodos de envoltura como RFE incorporan la selección de características como parte del proceso de capacitación para descartar las características irrelevantes. En este documento, se considera un enfoque de RFE-SVM para eliminar funciones ruidosas, así como para aprovechar el poder de discriminación de los clasificadores SVM. También se tiene expectativa en que estas estadísticas resultantes en los parámetros de selección de características ofrezcan nuevas observaciones sobre la derivación de características de la señal EEG.

CUARTA ETAPA (2016-2019)

MÉTODO PARA EL DIAGNÓSTICO AUTOMÁTICO DE LA EPILEPSIA USANDO CLASIFICADORES DE VALOR COMPLEJO

Los autores Musa Peker, Baha Sen, *Senior Member, IEEE*, y Dursun Denle, utilizaron para este artículo un modelo híbrido con la ayuda de la transformada de wavelet compleja de doble árbol (DTCWT) y Las redes neuronales de valor complejo CVANN de segundo nivel; El método (DTCWT) para selección y extracción de características y utilizando el algoritmo de red neuronal de valor complejo (CVANN) para su clasificación y así aumentar la productividad de CVANN. Aplicándolo en la detección de ataque epiléptico.

Las señales de EEG utilizadas como conjunto de datos en “como se citó anteriormente en metodología mixta de red wavelet-caos-neural para la detección de epilepsias y ataques epilépticos. Samanwoy et al., 2007. (Andrzejak 2001)”

El DTCWT utiliza filtros analíticos para realizar el análisis wavelet. El DTCWT tiene una estructura más compleja en comparación con el DWT estándar, y está compuesto por dos DWT que funcionan paralelos entre sí, además de esto suponga que la media aritmética pasa de 4096 los valores reales a 2048 muestras en un segmento es (x) y la media aritmética de los valores imaginarios es (y). En este caso, el valor de la característica aritmética media será $x + yi$ para esta muestra. Otros valores de características también se han calculado de esta manera.

En la literatura, se utilizaron características estadísticas en WT de valor real para la reducción de dimensiones. Sin embargo, dicha aplicación no se ha observado en aplicaciones DTCW. El valor de salida para pacientes con epilepsia es $(0 + i)$, el valor de salida para personas sanas es $(1 + i)$. Dado que este estudio emplea TCWT en los datos de tres niveles diferentes (Primero, segundo, y tercer nivel), hay tres problemas con diferentes datos de entrada.

Para mayor facilidad, estos tres problemas se llaman DTCWT-CVANN-1, DTCWT-CVANN-2, y DTCWT-CVANN-3, respectivamente, en términos de valores de nivel. Los valores de los parámetros de la CVANN fueron obtenidos por ensayo y error. la estructura CVANN es en realidad un modelo de ANN que procesa números complejos. En términos de este modelo, los vectores de valores

complejos se proporcionan como entradas para CVANN, CVANN se inicia con la ayuda de la transmisión de señales de entrada o datos complejos a través de la conexión, donde cada conexión tiene un peso asociado que mejora la señal que se transmite, donde las señales recibidas se transforman por cada neurona (la suma de la entrada se multiplica por el peso de la conexión) a través de una función de activación y, a su vez, la salida. Los mejores resultados para promedio exactitud clasificación se obtienen utilizando DTCWT + CVANN-1 y DTCWT + algoritmo CVANN-3 para la detección de ataque epiléptico.

Para el método propuesto se aplicaron 4 experimentos utilizando diferentes grupos y combinación de grupos clasificados de (A- E).

En el experimento uno: tres grupos pacientes sanos (A), pacientes con epilepsia en intervalos sin crisis (D) y pacientes con epilepsia (E). La notación se simplifica como A-D-E.

Para el experimento dos: los grupos A, B, C y D se incluyeron en la clase de no incautación y el conjunto E se incluyó en la clase de incautación. La notación se simplifica como ABCD-E.

En el experimento tres: se utilizaron cuatro grupos divididos en dos clases de datos. En la primera clase se emplearon series de no ataques que excluían a los sanos con los ojos cerrados (A, C, D) y en la segunda clase se usaron pacientes con epilepsia con crisis epilépticas (E). La notación se simplifica como ACD-E.

El experimento cuatro: se utilizaron cinco grupos divididos en tres clases, los sanos (AB), los pacientes con epilepsia en los intervalos libres de crisis (CD), y los pacientes con epilepsia con crisis epiléptica (E). Notación es AB-CD-E.

Este estudio propone un modelo híbrido para el análisis de señales de EEG con fines de diagnóstico de epilepsia con altos índices de exactitud fig. 25.

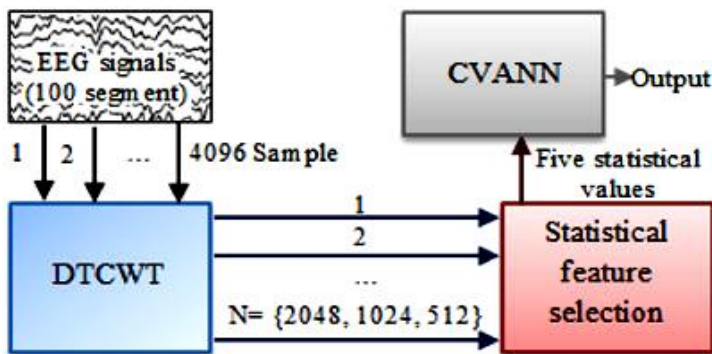


Fig.25 metodología propuesta donde se hace una preselección de 2048 ET tomado de "A Novel Method for Automated Diagnosis of Epilepsy Using Complex-Valued Classifiers 2016"

El efecto de los clasificadores de valor complejo demostrado tener un impacto positivo en la clasificación exactitud de datos de la señal del EEG.

Para el experimento 1 Se obtuvo una tasa de precisión del 99,3% con el método de validación cruzada diez veces y la tasa de precisión del 99,04% se obtuvo con el método de selección de datos de retención.

Para el experimento dos: Se obtuvo una tasa de precisión de 99.33% con el método de selección de datos de retención.

En el experimento tres: (ACD-E), tasa de precisión 98,37%.

En el experimento cuatro: Se obtuvo una tasa de precisión de 98.28%.

Para futuros estudios se pretende que este método se implemente en datos de EEG que involucren datos más grandes y más continuos.

DIAGNÓSTICO AUTOMATIZADO DE LA EPILEPSIA MEDIANTE UN PATRÓN BINARIO LOCAL BASADO EN PUNTOS CLAVE DE SEÑALES EEG

calcular las diferencias de señales Máxima y mínima (extremos) usando un bloque de clasificación para crisis epiléptica, normal y libre de crisis.

Los patrones binarios locales (LBP) se calculan en estos puntos clave y el histograma de estos patrones se considera como el conjunto de características, que se alimenta a la máquina de vectores de soporte (SVM) para la clasificación de las señales de EEG.

La metodología propuesta ha sido investigada para los cuatro problemas de clasificación bien conocidos, a saber, 1) crisis epilépticas y normales, 2) crisis epilépticas y libres de crisis, 3) crisis epilépticas normales y sin crisis, y 4) crisis epilépticas y sin crisis epilépticas Ya que en términos de precisión de clasificación se han comparado con los métodos existentes para la clasificación de los problemas mencionados anteriormente con buenos resultados Señales que se utilizan de la base de datos de EEG "como se citó anteriormente en metodología mixta de red wavelet-caos-neural para la detección de epilepsias y ataques epilépticos. Samanwoy et al., 2007. (Andrzejak 2001)."




fig 26 tomado y modificado de "Automated Diagnosis of Epilepsy Using Key-Point-Based Local Binary Pattern of EEG Signals 2017"

Además del conjunto de datos de EEG de la Universidad de Bonn, también se estudió un conjunto de datos de EEG recopilado en un hospital de Nueva Delhi. Este conjunto de datos consiste en registros de EEG digitalizados (con una frecuencia de muestreo de 400 Hz) de varios pacientes epilépticos. La adquisición de estas señales EEG involucró la colocación de 16 electrodos en el cuero cabelludo del sujeto de acuerdo con el sistema internacionalb10-20. El conjunto de datos se divide (con la ayuda de neurólogos) en dos subconjuntos, con el primer subconjunto que contiene señales de EEG capturadas durante la actividad convulsiva y el segundo con señales de EEG libres de crisis del mismo conjunto de pacientes. Cada uno de estos subconjuntos contiene 100 segmentos de señal EEG, cada uno con una duración de 3 s. presenta señales típicas de

EEG que pertenecen a clases de incautación y de convulsiones en este conjunto de datos. Este conjunto de datos se ha utilizado para evaluar el rendimiento del método propuesto para el segundo problema de clasificación (con y sin incautación).

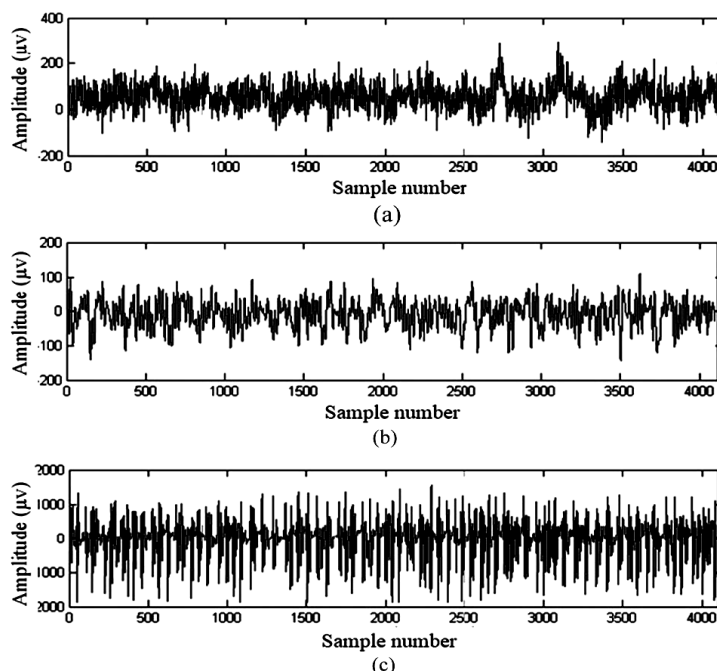


Fig. 27. Las señales de EEG de muestra del conjunto de datos de EEG de Bonn correspondientes a las convulsiones normales (N), sin convulsiones (SF) y epilépticas (ES) se muestran en (a), (b) y (c), respectivamente. extraído del artículo.

Después de calcular el histograma de la LBP como la característica de discriminación, la tarea final es clasificar una señal de EEG dada en una de las tres clases, correspondientes a normal (N), sin crisis (SF) y epiléptica (ES) se muestran en (a), (b) y (c), respectivamente fig. 27. En este estudio, se utilizó el clasificador SVM para la clasificación de señales EEG. Más específicamente, el clasificador SVM con función de base radial (RBF) kernel disponible en la caja de herramientas de aprendizaje automático WEKA. En todos los experimentos, se estableció el parámetro de compensación de la SVM y el parámetro sigma del kernel RBF en 2.395 y 0.1, respectivamente.

La técnica de detección de punto clave empleada en este estudio consiste en convertir la señal de EEG con un conjunto de filtros gaussianos para suavizar la señal progresivamente, lo que se logra al incrementar la escala (desviación estándar) de la función gaussiana.

Máximos y mínimos (extremos) en cada nivel de esta pirámide forman el conjunto de puntos clave. Estos puntos clave se identifican comparando un valor de muestra en la señal filtrada Do G con sus dos vecinos inmediatos y tres vecinos cada uno en los dos niveles adyacentes (superior e inferior) en la pirámide. El método propuesto se ha evaluado utilizando diez veces la validación cruzada y las medidas de rendimiento comúnmente utilizado (ACC), (SEN), (SPE), el valor predictivo positivo (PPV), el valor predictivo negativo (NPV) y el coeficiente de correlación de Matthews (MCC). Cabe señalar que cuanto mayor sea el valor de MCC, mejor será el rendimiento del clasificador.

E-mail: dte_jmmoralesz389@pedagogica.edu.co (Julián M. Morales Zabala)

© 2019 Universidad Pedagógica Nacional (Algoritmos para la detección de epilepsia con uso de EEG)

En el método propuesto, hay dos parámetros, a saber, el número de niveles (M) en la pirámide DoG y la escala inicial (σ_1) del filtro gaussiano. En todos nuestros experimentos, hemos establecido el valor de σ_1 a 0.5. Dado que los parámetros de escala de los filtros gaussianos sucesivos están relacionados con el uno a través de (2), las frecuencias de corte de 3 dB de los cuatro filtros gaussianos son 61.9, 25.5, 18.5 y 13 Hz

El rendimiento del método propuesto es bastante alentador incluso cuando solo se utilizan 1000 muestras de la señal de EEG para la clasificación. Además, se sabe que el descriptor de LBP empleado es un método computacionalmente simple. Las características antes mencionadas del método lo hacen potencialmente útil para la detección de ataques en tiempo real en dispositivos con bajos recursos computacionales y de memoria. Por otro lado, el tamaño de los conjuntos de datos de EEG utilizados en este estudio para la evaluación del rendimiento es limitado. Por lo tanto, se debe evaluar en bases de datos más grandes antes de su despliegue clínico. El rendimiento del método propuesto se ha comparado con los métodos existentes para la clasificación de estos cuatro problemas de clasificación en términos de precisión de clasificación en el conjunto de datos de EEG de la Universidad de Bonn. El método propuesto ha proporcionado una mejora constante en la precisión de la clasificación con respecto al método convencional basado en LBP.

La importancia clínica del método propuesto se deriva de sus características clave, que incluyen una alta precisión de clasificación y la simplicidad computacional de las características LBP. Más importante aún, la metodología propuesta ha proporcionado una precisión de clasificación suficientemente alta, incluso con un segmento considerablemente más pequeño de la señal EEG, lo que la hace adecuada para la detección de epilépticos en línea con una carga computacional reducida.

DETECCIÓN DE CRISIS EPILÉPTICAS EMPLEANDO UN NUEVO CONJUNTO DE CARACTERÍSTICAS EXTRAÍDAS DEL ESPECTRO MULTIFRACTAL DE SEÑALES DE ELECTROENCEFALOGRAMA

Objetivo de los autores Rohit Bose¹, Sawon Pratiher, y Soumya Chatterjee. fue implementar el Análisis de Fluctuación de tendencia Multifractal (MFDFA) de los EEG como técnica de extracción de características que indiquen la diferencia de altura entre la media y los valores extremos mínimo y máximo de los espectros de singularidad fig.28.

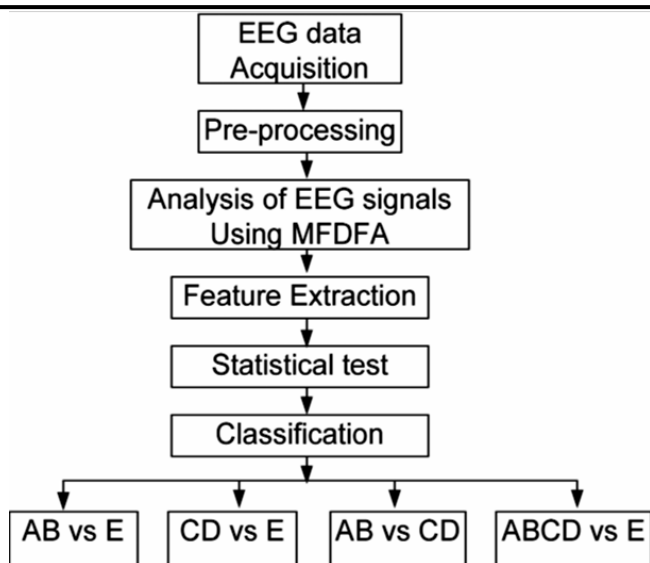


Fig.28.diagrama de metodología con cuatro tipos de problemas (Tomado de Detection of epileptic seizure employing a novel set of features extracted from multifractal spectrum of electroencephalogram signals).

En este estudio se utilizará la base de datos de la universidad de Bonn, Alemania “como se citó anteriormente en metodología mixta de red wavelet-caos-neural para la detección de epilepsias y ataques epilépticos. Samanwoy et al., 2007. (Andrzejak 2001)”

La técnica de extracción usando (MFDFA) da como resultado 14 características del espectro multifractal (MS) seleccionadas. Se evalúa usando la prueba de Kruskal-Wallis y finalmente se sirve como función de entrada de vector a un soporte máquinas de vectores clasificadores (SVM).

Para la clasificación de las señales de EEG. Se presentan cuatro problemas de clasificación en este trabajo y se observa que se obtiene el 100% de precisión de clasificación en rendimiento de (SVM). De los tres problemas que validan la eficacia del modelo propuesto para el diagnóstico asistido por ordenador de la epilepsia.

En las ecuaciones anteriores, verdadero positivo (TP), falso negativo (FN), falso positivo (FP) y verdadero negativo (TN), se evalúan a partir de la matriz de confusión respectiva para los ocho problemas de clasificación. Por un lado, verdadero negativo positivo y verdadero significa el número de casos clasificados correctamente y, por otro lado, de falsos negativos y falsos positivos significan el número de casos mal clasificados.

El método propuesto produjo una precisión máxima de 100%. Para P-III, la máxima exactitud de 96,25% se consigue en este trabajo. Además de la precisión de clasificación, especificidad sensibilidad y la precisión del 100% se obtienen en el presente trabajo para los problemas I, II y IV, respectivamente tabla 6.

Problem type	Acc %	Sen %	Spe %	Pre %
P-I (AB,E)	100.00	100.00	100.00	100.00
P-II (CD,E)	100.00	100.00	100	100.00
P-III (AB,CD)	96.25	95.44	97.06	97.50
P-IV (ABCD,E)	100.00	100.00	100.00	100.00

Tabla. 6. precisión de la clasificación Tomado de “Detection of epileptic seizure employing a novel set of features extracted from multifractal spectrum of electroencephalogram signals”.

Las cifras correspondientes para P-III son 95,44%, 95,44% y 97,50, respectivamente. Por lo tanto, se puede decir que el método propuesto emplea funciones basadas en MFDFA y SVM clasificador es altamente sensible y también puede discriminar las señales de EEG libres de crisis saludable, interictal y a partir de señales de convulsiones con la máxima precisión.

UN ENFOQUE BINARIO LOCAL HÍBRIDO Y UN ENFOQUE BASADO EN WAVELETS PARA LA CLASIFICACIÓN DEL EEG PARA EL DIAGNÓSTICO DE LA EPILEPSIA

Los datos EEG se recogieron de la base de datos del cuero cabelludo CHB-MIT disponible abiertamente para fines de investigación (Shoeb & Guttag, 2010). los datos se registraron en el hospital de Boston children’s de 23 sujetos y un sujeto nuevo incluido más tarde todos pediátricos con convulsiones intratables marcadas durante el período de epilepsia para un total de 916 horas de grabación continua cada uno con una a cuatro horas de datos digitalizados La mayoría de los sujetos tenían un tamaño de archivo de una hora de duración. También hubo sujetos con múltiples ataques en un solo archivo. La señal EEG en estos datos se muestreó a 256 Hz con una resolución de 16 bits, La mayoría de los sujetos tenían grabaciones tomadas en 23 canales. Se utilizó el sistema internacional 10-20 de colocación de electrodos. Los montajes con configuración idéntica se consideraron para la clasificación de las convulsiones, el clasificador particular devuelve la etiqueta lógica 1 para representar una época como incautación, y la etiqueta lógica 0 representa una época EEG normal. Para reducir el FDR debido a los artefactos, también se emplearon técnicas de procesamiento posterior, de tal manera que, si un segmento de 5 segundos consecutivos muestra 4 etiquetas como 1 en 14 canales de entre 22 canales, ese segmento se considera como un segmento de captura.

Para el presente trabajo se seleccionaron 14 pacientes al azar (con montaje bipolar similar) de la base de datos fueron probados con el algoritmo para la clasificación de convulsiones. Se probaron un total de 498,9 horas de datos que consta de 105 convulsiones.

Para este algoritmo primero se hace un preprocesamiento consistente en filtrar primero los artefactos, Por lo tanto, el filtro Butterworth se usa comúnmente para la eliminación de fallas agudas (ruido de alta frecuencia) en la señal EEG (M. Rangayyan, 2002; Orosco et al., 2016) ya que proporciona el equilibrio óptimo entre varios parámetros para eliminar el ruido de alta frecuencia (artefactos) mientras se mantienen los componentes de la

señal EEG. Después se utilizan los Patrones binarios locales (LBP) en todos los canales de cada paciente logrando una señal LBP transformada la cual abre épocas de 1s con 256 muestras cada una.

Enseguida se utiliza DWT de cinco niveles de descomposición interpretada usando wavelet de Haar sobre cada época, esta descomposición será son los coeficientes aproximados que significan la frecuencia más baja, mientras que los coeficientes detallados significan la frecuencia más alta en cada nivel de descomposición.

La extracción de características se hace a partir de los coeficientes obtenidos en A5 calculando características univariadas de Kurtosis, MAD, IQR y Semivarianza debido a que las características univariadas a menudo no logran capturar la variabilidad de la señal se usa correlograma bivariado a medida que se van integrando las características.

Para la clasificación el análisis discriminante se realizó para clasificar entre convulsiones y EEG normal (Orosco et al., 2016). Las características extraídas de los coeficientes wavelet forman un vector de características por época por canal. Estos vectores de características de los ataques y los segmentos normales se agruparon en dos clases. El entrenamiento y las pruebas se realizaron para proporcionar una clasificación de las convulsiones del EEG normal. La relación entre entrenamiento y pruebas de ataques se tomó como resultado de la clasificación, estos se validaron mediante validación cruzada triple para evaluar la robustez del presente algoritmo.

Se realizó una validación cruzada triple para el análisis del algoritmo en la base de datos de este paciente epiléptico. El promedio de los resultados de validación cruzada se realiza para producir un rendimiento final del presente algoritmo.

Para mayor certeza de no caer en FDR primero se declara incautación a un segmento en un canal con más de cuatro épocas marcadas de cinco segundos consecutivos o si el 60% de los canales presentan incautación en el segmento. También se utilizan parámetros de evaluación estándar ver (3), (4), (5).

como conclusión se propone una técnica automática para la clasificación de EEG en pacientes epilépticos utilizando un enfoque híbrido del algoritmo LBP-wavelet para la detección de convulsiones. Este algoritmo puede lograr una sensibilidad del 100% con una especificidad media del 99,8% cuando se trabaja en más horas en comparación con otros trabajos en la misma base de datos ver tabla (7). El alcance futuro de esta investigación es crear un sistema basado en el algoritmo propuesto para el monitoreo continuo de EEG para pacientes epilépticos en condición hospitalizada. También es prometedor desarrollar terapia de medicación automática a través de dispositivos implantados mediante la implementación en tiempo real de la técnica propuesta para la clasificación de EEG.

DIAGNÓSTICO AUTOMÁTICO DE EPILÉPTICO INCAUTACIÓN DE SEÑALES ELECTROENCEFALOGRAFÍA EL USO DE DINÁMICA NO LINEAL

El principal objetivo de este artículo es investigar el rendimiento del algoritmo discreta de Wavelet (DWT) y el clasificador LS-SVM (Support Vector Machine).

Mediante la resolución de un conjunto de ecuaciones lineales, para eliminación del ruido de las EEG. Y así discriminar los estados Ictal e interictal de las señales EEG. Como metodología para este caso se usan un conjunto de datos EEG obtenido del Departamento de Epileptología, de la Universidad de Bonn, Alemania y contiene cinco subconjuntos nombrados “como se citó anteriormente en metodología mixta de red wavelet-caos-neural para la detección de epilepsias y ataques epilépticos. Samanwoy et al., 2007. (Andrzejak 2001)” Las señales se dividen en dos conjuntos de base de datos: la base de entrenamiento y la base de prueba. Con, los siguientes pasos:

Primero se realiza para descomponer las señales EEG en seis señales de sub-banda, para ello se aplica DWT para alterar las señales de EEG. DWT contiene una gran cantidad de funciones básicas diferentes, que proporcionan una variedad de opciones para las señales de EEG en diferentes estados que podrían coincidir con las características de las señales de EEG durante la incautación, en este caso DWT se encarga de descomponer señales de un solo canal en sub-bandas usando Daubechies-4 (DB4), con las que se podría extraer nuevas características y mejorar la precisión en el diagnóstico obteniendo coeficientes residuales con cinco señales de detalle (d1-d5) provenientes de los conjuntos de base de datos (S y F) ictal e interictal respectivamente La frecuencia de las señales de ataque EEG es comúnmente entre 3 y 25 Hz. La frecuencia de las señales de detalle d1

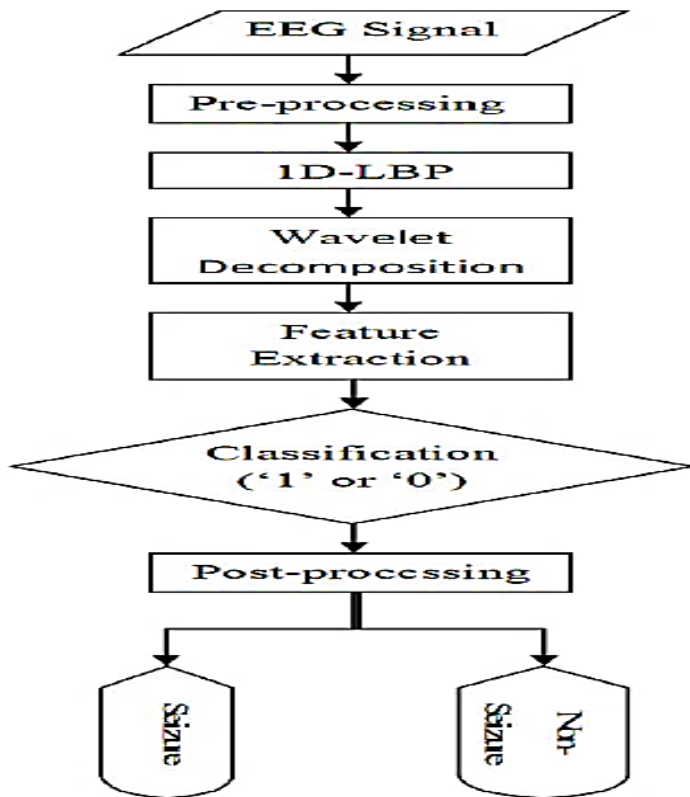


Fig.29. metodología propuesta tomada de “A hybrid Local Binary Pattern and Wavelets based approach for EEG classification for diagnosing epilepsy.2019”.

y d2 está fuera del rango de frecuencia de las señales de EEG durante las crisis epilépticas, los canales (d3, d4, d5) se usan para calcular las características de entropía.

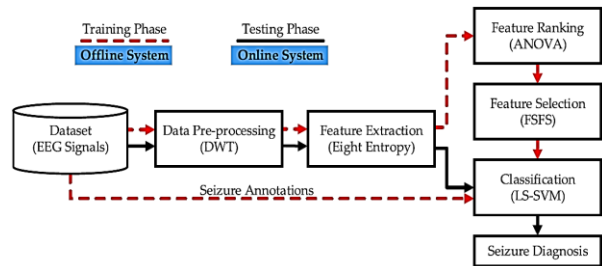


Fig.30. metodología. (Tomado de Automatic Diagnosis of Epileptic Seizure in Electroencephalography Signals Using Nonlinear Dynamics Features).

Segundo se toma un conjunto de ocho medidas de entropía diferentes: la entropía aproximada (ApEn) podría clasificar de manera confiable las señales deterministas, caóticas y estocásticas en el comportamiento episódico subyacente y refleja la probabilidad de que patrones similares de observaciones no sean seguidos por observaciones similares adicionales; la entropía espectral (SE) el cual mide el grado de desorden de las señales incorporado en la distribución de frecuencia de los componentes de amplitud del espectro de potencia de una señal. Cuando la potencia de las señales se concentra en una sola frecuencia, SE es mínima; la entropía Fuzzy (FE); estima incertidumbres ambiguas de las señales con solidez al ruido, que es muy sensible a los cambios en el contenido de la información; la entropía muestral (SampEn) es una modificación de ApEn y se utiliza para evaluar la complejidad de las señales de series de tiempo fisiológicas y diagnosticar estados de enfermedad.

SampEn supera a ApEn con dos ventajas, a saber, la independencia de la longitud de los datos y la implementación relativa sin problemas; Permutación entropía (PE) es una medida de señales no estacionarias basada en el análisis de patrones de permutación.

PE mide la información basada en la aparición o ausencia de ciertos patrones de permutación de la clasificación de valores en las señales. Al aplicar PE, una señal dada se transforma en una serie de patrones ordinales. Y cada patrón describe la relación secuencial entre el actual y un número fijo de valores pasados equidistantes en un momento dado. PE tiene las ventajas de baja complejidad computacional y robustez frente a datos ruidosos; la entropía de Shannon (Shanen) es parte de la teoría de la información a fines de la década de 1940; Condicional entropía (conden) cuantifica la cantidad de información requerida para describir el resultado de una variable aleatoria en el caso del valor de otra variable aleatoria conocida. CondEn podría distinguir la diferencia entre patrones periódicos y dinámicas aperiódicas; y la entropía condicional corregido (CCE) La incertidumbre de una serie temporal completamente estocástica, con un comportamiento no determinado, para superar esta limitación, se propone y se da CCE; Se extraen de las señales de sub-banda reconstruidas a partir de los detalles y coeficientes aproximados. con el uso de estos ocho algoritmos de entropía se calcularon 24 características.

Respecto a los valores resultantes de F se calcularon usando la clasificación de características y método de selección de Análisis Unidireccional de la Varianza (ANOVA) y la Función de selección de características secuenciales hacia adelante (FSFS) se aplican para seleccionar las características de acuerdo a su significación y mejorar el rendimiento de la clasificación, generado un subconjunto óptimo de 18 características; por último se usó el método de clasificación (LS-SVM) que presenta menos carga computacional que solo (SVM), y la evaluación del rendimiento medidas. Finalmente se presentan las conclusiones.

En el análisis comparativo se usaron cinco algoritmos de referencia:

- K-vecinos más cercanos (KNN): KNN es un clasificador base de caso en el que una nueva instancia se clasifica de acuerdo con las muestras de entrenamiento más cercanos presentes en el espacio de características. La nueva observación se asigna a una clase que está más cerca entre sus vecinos K. En este estudio, seleccionamos $K = 2$.
- Regresión logística (LR): LR mapea la combinación lineal ponderada de valores propios a los valores reales entre 0 y 1 interpretado como probabilidades mediante el uso de la función logística [47]. Al establecer el valor umbral y determinar si la salida de la regresión logística es mayor o menor que el umbral para ejecutar clasificación binaria.
- Análisis discriminante lineal (LDA): LDA se utiliza para construir un modelo de clasificación lineal que crea un límite lineal entre dos grupos. El LDA es muy popular debido a su linealidad permite una fácil estimación de la probabilidad posterior de cada grupo.
- Naive Bayes Classifier (NB): NB es un clasificador probabilístico basado en el Teorema de Bayes con la suposición de que las variables de predicción son variables aleatorias independientes. El clasificador NB es capaz de probabilidades de computación requeridos por la fórmula de Bayes con incluso una pequeña formación de datos.
- Bosque aleatorio (RF): RF es una técnica de empaquetamiento que combina el rendimiento de numerosos algoritmos de árbol de decisión para la clasificación o la regresión. Cuando llega una nueva instancia, RF agrupa K árboles de clasificación y clasifica los resultados por voto mayoritario o política promedio para un área de capacitación determinada.

Methods	Accuracy (%)	Sensitivity (%)	Specificity (%)
LS-SVM	99.50	100.00	99.40
KNN	97.90	99.80	94.00
LR	99.00	100.00	98.00
LDA	99.00	100.00	99.00
NB	91.00	98.00	84.00
RF	97.00	99.00	95.00

tabla.7 (Tomado de Automatic Diagnosis of Epileptic Seizure in Electroencephalography Signals Using Nonlinear Dynamics Features).

Como resultado el método LS-SVM resulto ser más eficiente en todos los ítems de actuación, sensibilidad, especificidad el método usado podría utilizarse no solo en EEG sino también para detectar anomalías en otras señales biomédicas como electromiograma (EMG), electrocardiograma (ECG), y magneto-encefalograma (MEG) tabla (7).

ANÁLISIS DE LAS ETAPAS PROPUESTAS

ETAPA (2000 a 2005)

Para la primera etapa de artículos encontrados, observamos que en el año 2000 a 2005 ya se proponen sistemas de procesamientos de señal EEG con múltiples métodos donde se integran redes neuronales y sistemas de filtro basado en ANN (He Sheng Liu 2002) y con un aumento en el número de fases para el desarrollo de la metodología, para esta primera selección se observa en los artículos una discriminación de los registros por umbrales de ondas lentas y picos, (según Gotman 1997 las ondas lentas interictales también pueden desempeñar un papel importante para el diagnóstico, especialmente en muchos casos, cuando no aparecen los transitorios bruscos). Además, el uso de backpropagation usado continuamente tanto para la detección y como para un sistema posclasificador (Nurettin Acir 2005) no se llevan a cabo pruebas de detección de picos directamente de los datos sin procesar a entrada ANN como clasificador es decir todos los datos pasan por el proceso de filtrado para esta etapa los métodos se centran en una exhaustiva caracterización de las ondas.

ETAPA (2006 a 2010)

Ya en la segunda etapa de artículos se tienen en cuenta la caracterización de los eventos transitorios anormales asociados a artefactos (Themis P. Exarchos 2006). además se muestran algoritmos de clasificación que no necesitan necesariamente de la discretización de características e igual generan un modelo de clasificación, Todos los pasos de las metodologías propuestas son automatizados en su mayoría. ; vemos que los trabajos desarrollados con anterioridad utilizan redes neuronales artificiales con procesamiento wavelet, en cambio para esta segunda etapa además de utilizar aplicaciones integradas simultáneamente como metodología de bandas mixtas de wavelets, teoría del caos, y redes neuronales para el análisis de EEG, también se obtiene un primer acercamiento con el análisis de sub-bandas una primera investigación para seleccionar parámetros de varias sub-bandas fisiológicas de EEG y usarlos simultáneamente como entrada para clasificadores cambiando el esquema manejar de la dinámica del cerebro como un todo y postulando que la señal EEG representa la superposición de diversos procesos en el cerebro aumenta en los trabajos realizados el uso de algoritmos híbridos (Samanwoy Ghosh-Dastidar 2008) con el fin de mejorar tanto la caracterización como la clasificación se demostró que las redes neuronales artificiales (ANN) pueden ofrecer un método potencialmente superior del análisis de señales de EEG en comparación con los métodos de análisis espectral (Elif Derya U" beyli 2008).

ETAPA (2011-2015)

en la etapa tres las pruebas de selectividad, sensibilidad, precisión se realiza distinciones más específicas como eventos verdaderamente positivos, verdaderos negativos, falsos positivos y falsos negativos, respectivamente; También se presenta un estudio sobre las diversas combinaciones de características. A medida que el enfoque propuesto está libre de cualquier decisión basada umbral estático. (Sourya Bhattacharyya 2011). de los resultados obtenidos teniendo en cuenta estos parámetros la descomposición de la señal se da por sentado a lo largo de toda selección propuesta dividiéndola señal en sub-bandas, los métodos de caracterización en su mayoría son iterativos debido a que se tiene más certeza de las características de las ondas ictales, interictales y normales, se hace diferenciación entre estos tres grupos aplicando los algoritmos por separado, se ha propuesto un método de detección convulsión basado en el uso de los momentos estadísticos de orden superior tales como varianza, asimetría y curtosis. (S. M. Shafiul Alam 2013) asimismo se logró la sensibilidad perfecta, donde todas las convulsiones, pronosticado con éxito de antemano para 98,8% en el pronóstico en el que 82 de 83 ataques en el conjunto de la evaluación se han predicho (Ning Wang 2015)

ETAPA (2016-2019)

En la cuarta etapa de artículos además se utilizan sistemas híbridos de ANN simultáneamente lo que permite hacer comparativas de los que mejor caracterizan o seleccionan la detección además se crean algoritmos utilizando LDA el cual proporciona modelos de entrada y salida basado en variables la cual combinada con NB por ejemplo es capaz de identificar que una característica no está relacionada con otra. Así como también precisión de la clasificación sobre el método convencional basado en LBP. La importancia clínica del método propuesto surge de sus características clave, que incluyen una alta precisión de clasificación y simplicidad computacional de las características de LBP.(Ashwani Kumar Tiwari 2017)Se prevé que estos altos niveles de las tasas de precisión de la predicción también se pueden obtener en diferentes señales biomédicas campos procesamiento (Musa Peker 2016) en métodos propuestos MFDDFA son capaces de capturar la no linealidad de las señales de EEG más precisión durante el inicio ataque epiléptico y pueden discriminar eficazmente desde saludable y interictal.(Rohit Bose,2018). sin embargo, los métodos híbridos de aprendizaje supervisado como LS-SVM presentan un mejor rendimiento considerando que SVM se viene trabajando con más énfasis, El objetivo principal de LS-SVM es aplicar la minimización de la suma de los errores de cuadrados a la función objetivo. (Shanen CHEN,2019).

CONCLUSIÓN

las dificultades en el manejo de la epilepsia resistente al tratamiento pueden mejorarse por la capacidad de detectar convulsiones. Estos sistemas de detección y predicción tempranos podrían abortar las convulsiones a

través de terapias dirigidas, los sistemas de detección y predicción aquí descritos están disponibles actualmente para las crisis epilépticas. Se explora además la posible aplicación de dichos sistemas en la monitorización ambulatoria y los modelos de circuito cerrado para la atención individual de pacientes. Un sistema de detección de ataques debe poder determinar la presencia o ausencia de ataques continuos.

Los métodos automatizados de análisis EEG están surgiendo del concepto de que la dinámica cerebral normal, que implica una sincronización limitada y transitoria de la actividad neuronal desorganizada, y evoluciona a un estado persistente y altamente sincronizado que incorpora grandes regiones del cerebro durante las crisis epilépticas, los avances en los métodos de aplicación algorítmica han avanzado y aumentando la confiabilidad en la detección de crisis y la reducción de tiempo en el diagnóstico de las patologías epileptiformes mediante métodos no invasivos.

BIBLIOGRAFIA

R. G. Andrzejak, G. Widman, K. Lehnertz, C. Rieke, P. David, and C. E. Elger. (2001)

"The epileptic process as nonlinear deterministic dynamics. in a stochastic environment: An evaluation on mesial temporal lobe epilepsy," *Epilepsy Res.*, vol. 44, pp. 129-140, 2001. http://epileptologiebonn.de/cms/front_content.php?idcat=193&lang=3&changelang=3

T. Oates R.T.G, Merry (1993)

Electroencephalogram epileptiform abnormalities in candidates for aircrew training R.P. Gregory. *Electroencephalogr Clin. Neurophysiol.* 1993; 86:75-77.

Zivin L, Ajmone-Marsan C. (1968)

Incidence and prognostic significance of "epileptiform" activity in the EEG of nonepileptic subjects. *Brain* 1968; 91:751-778

Kellaway Peter. (2003)

Orderly Approach to Visual Analysis: Elements of the Normal EEG and Their Characteristics in Children and Adults. In: Ebersole JS, Pedley TA, Eds. *Current Practice of Clinical Electroencephalography*, 3rd edition, 2003:100-159

J. Ma. Mercade Cerda, Sancho Rieger. (2012).

Guías diagnósticas y terapéuticas de la Sociedad Española de Neurología 2012. 1. Guía oficial de práctica clínica en epilepsia © 2012, Sociedad Española de Neurología ISBN obra completa: 978-84-7989-750-5.

Robert S. Fisher, J. Helen Cross, Jacqueline A. French, Norimichi Higashimura, Edouard Hirsch, Floor E. Jansen. (2017).

Clasificación operacional de los tipos de crisis por la Liga Internacional contra la Epilepsia: Documento - Posición de la Comisión

para Clasificación y Terminología de la ILAE: <https://www.ilae.org/files/ilaeGuideline/Spanish-Traduccion-Fisher-Seizure-types.pdf>

Luis Enrique Morillo Zarate, (2005)

"Análisis visual del electroencefalograma" Guía Neurológica 7 - Neuro Electro Diagnóstico. En: Colombia ISBN: 0 ed.: Asociación Colombiana de Neurología, v.7, p.143 - 163 7.

<https://www.acnweb.org/guia/g7cap17.pdf>

Eslava J, Espinosa E, Izquierdo A, Medina-Malo C, Nariño D, Carreño O. (2006)

Consenso Colombiano de Epilepsia. *Acta neurológica colombiana* vol. 22 no. 4 • suplemento (1:1) 2006 issn 0120-8748 publicación oficial de la asociación acta neurológica colombiana 2006; 22:365-404 colombiana de neurología.

https://www.acnweb.org/acta/2006_22_4s_in.pdf

Huang LT, Cilio MR, Silveira DC, (1999).

Long term effects of neonatal seizures: a behavioral electrophysiological and histological study. *Dev Brain Res* 1999; 118: 99-107 https://scielo.conicyt.cl/scielo.php?script=sci_nlink&ref=7506376&pid=S0370-4106200100030000200021&lng=es

Jonathan González Sánchez (2014)

Técnicas De Toma De Datos Y Análisis De Electroencefalografía

<http://opera.eii.us.es/sinergia/public/uploads/sinergia/entregables/2013-2014/G2013-20149/Grupo9Memoria1.pdf>

Juan Bernardo Vázquez Gómez. (2012).

Análisis y diseño de algoritmos ISBN 978-607-733-053-0 Primera edición:2012 Red Tercer Milenio S.C. Mexico ISBN 978-607-733-053 0

http://www.aliat.org.mx/BibliotecasDigitales/sistemas/Analisis_y_diseño_de_algoritmos.pdf

Victoria Peterson, Yanina Atum, Florencia Jauregui, Iván Gareis, Rubén Acevedo, y Leonardo Rufiner. (2013).

Detección de potenciales evocados relacionados a eventos en interfaces cerebro-computadora mediante transformada wavelet Facultad de Ingeniería, Universidad Nacional de Entre Ríos, Argentina. *Revista Ingeniería Biomédica*.

Diego Andrés Candia Rivera (2016)

Caracterización De La Respuesta Emocional Ante Estímulos Visuales En Registros Electroencefalográficos.

<http://repositorio.uchile.cl/bitstream/handle/2250/143582/Caracterizaci%C3%B3n-de-la-respuesta-emocional-ante-est%C3%ADmulos-visuales-en-registros->

electroencefalogr%C3%A1ficos.pdf?sequence=1&isAllowed=y&fbclid=IwAR3bQvgt1lWoAJ42b5PJoaW6JLanRn16a7N5b8-S00kasl99MGIJAjTjdaw

Sophie Helene Bischel (2013).

El Método De La Entropía Cruzada. Algunas Aplicaciones. Escuela Politécnica Superior Y Facultad De Ciencias Experimentales.

http://repositorio.ual.es:8080/bitstream/handle/10835/3322/Trabajo.pdf?sequence=1&isAllowed=y&fbclid=IwAR1a_bG7jZf50ULnrLlcTpgFJRhTdE3MtlzUJyLcGvxzz9PuG9fzctBxi9c

Enrique J. Carmona Suárez (2013).

Tutorial sobre Máquinas de Vectores Soporte (SVM) Dpto. de Inteligencia Artificial, ETS de Ingeniería Informática, Universidad Nacional de Educación a Distancia (UNED), C/Juan del Rosal, 16, 28040-Madrid (España).

http://www.ia.uned.es/~ejcarmona/publicaciones/%5B2013Carmona%5D%20SVM.pdf?fbclid=IwAR25cf3B0Y2Zsi3p6KYWesl3qbU12XZZG1QqniMvw-VyOz_ZQwZEu7SdTc

Descomposición en modo empírico (2007).

<http://perso.enslyon.fr/patrick.flandrin/emd.html>

Pablo F. Verdes (2000).

Detection and Prediction of Epileptic Seizures: A Patient's Case Study Instituto de Física Rosario JOURNAL ON EMERGING AND SELECTED TOPICS IN CIRCUITS AND SYSTEMS, VOL. 1, NO. 4, DECEMBER (CONICET-Universidad Nacional de Rosario), Argentina verdes@ifir.edu.ar

He Sheng Liu, Tong Zhang, and Fu Sheng Yang. (2002)

A Multistage, Multimethod Approach for Automatic Detection and Classification of Epileptiform EEG Transactions On Biomedical Engineering, Vol. 49, No. 12.

Nurettin Acir, İbrahim Öztura, Mehmet Kuntalp, Baris Baklan, and Cüneyt Güzelis (2005).

Automatic Detección of Epileptiform Events in EEG by a Three-Stage Procedure Based on Artificial Neural Networks EEG Transactions On Biomedical Engineering, Vol. 52, No. 1, January 2005

Themis P. Exarchos, Alexandros T. Tzallas, Dimitrios I. Fotiadis, Spiros Konitsiotis, and Sotirios Giannopoulos. (2006).

Transactions On Information Technology In Biomedicine, Vol. 10, No. 3, July 2006 451 EEG Transient Event Detection And Classification Using Association Rules.

Samanwoy Ghosh-Dastidar, Hojjat Adeli, and Nahid Dadmehr, (2007).

Transactions On Biomedical Engineering, Vol. 54, No. 91545 Mixed-Band Wavelet-Chaos-Neural

Network Methodology for Epilepsy and Epileptic Seizure Detection.

Samanwoy Ghosh-Dastidar, Hojjat Adeli, and Nahid Dadmehr.(2008).

Transactions On Biomedical Engineering, Vol. 55, No. 2, February 2008 Principal Component Analysis-Enhanced Cosine Radial Basis Function Neural Network for Robust Epilepsy and Seizure Detection.

Elif Derya U' beyli (2009)

Eigenvector Methods for Automated Detection of Electrocardiographic Changes in Partial Epileptic Patients, Transactions On Information Technology In Biomedicine, Vol. 13, No. 4.

Petros Xanthopoulos, Steffen Rebennack, Chang-Chia Liu, Jicong Zhang, Gregory L. Holmes, Basim M. Uthman, and Panos M. Pardalos.(2010).

A novel wavelet based algorithm for spike and wave detection in absence epilepsy.

Ye Yuan. (2010).

Detection of Epileptic Seizure Based on EEG Signals. Department of Electronics Engineering Shantou University Shantou, China.

Sourya Bhattacharyya, Arunava Biswas, Jayanta Mukherjee, Arun Kumar Majumdar, Bandana Majumdar, Suchandra Mukherjee, and Arun Kumar Singh (2011).

Feature Selection for Automatic Burst Detection in Neonatal Electroencephalogram. Journal On Emerging And Selected Topics In Circuits And Systems, Vol. 1, No.4.

Azian Azamimi Abdullah, Saufiah Abdul Rahim and Adira Ibrahim. (2012).

Development of EEG-based Epileptic Detection using Artificial Neural Network. 2012 International Conference on Biomedical Engineering (ICoBE),27-28 February 2012, Penang.

S. M. Shafiul Alam and M. I. H. Bhuiyan (2013)

Detection of Seizure and Epilepsy Using Higher Order Statistics in the EMD Domain, Journal Of Biomedical And Health Informatics, Vol. 17, No. 2.

C.F. Reyes, T. J. Contreras, B.Tovar, and L.I.Garay. (2013).

Detection of Absence Epileptic Seizures Using Support Vector Machine. 2013 10th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE) Mexico City, Mexico.

Ning Wang, and Michael R. Lyu. (2015)

Extracting and Selecting Distinctive EEG Features for Efficient Epileptic Seizure Prediction, Journal

Musa Peker, Baha Sen, and Dursun Denle. (2016).

A Novel Method for Automated Diagnosis of Epilepsy Using Complex-Valued Classifiers Journal Of Biomedical And Health Informatics, Vol. 20, No. 1.

Ashwani Kumar Tiwari, Ram Bilas Pachori, Vivek Kanhangad, and Bijaya Ketan Panigrahi. (2017).

Journal Of Biomedical And Health Informatics, Vol. 21, No. 4, Automated Diagnosis of Epilepsy Using Key-Point-Based Local Binary Pattern of EEG Signals.

Rohit Bose, Sawon Pratiher, Soumya Chatterjee (2018)

Detection of epileptic seizure employing a novel set of features extracted from multifractal spectrum of electroencephalogram signals, Institute for Neurotechnology, National University of Singapore.

J. Gotman, D. Flanagan, J. Shang, and B. Rosenblatt, (1997)

“Automatic seizure detection in the newborn: Methods and initial evaluation,” Electroenceph.Clin. Neurophysiol., vol. 103, no. 3, pp. 356–362,

Kashif Ahmad Khan, Muhammed Shanir P. P., Yusuf Uzzaman Khan, Omar Farooq. (2019).

A hybrid Local Binary Pattern and Wavelets based approach for EEG classification for diagnosing epilepsy.

Shanen Chen, Xi Zhang, Lili Chen, And Zhixian Yang (2019)

Automatic Diagnosis of Epileptic Seizure in Electroencephalography Signals Using Nonlinear Dynamics Features Department of Industrial Engineering and Management, Peking University, Beijing 100871, China, Department of Pediatrics, Peking University First Hospital, Beijing 100034.