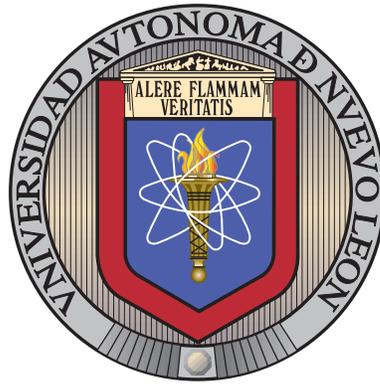


UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA

DIVISIÓN DE ESTUDIOS DE LICENCIATURA



SISTEMA DE RECONOCIMIENTO DE PATRONES EPILÉPTICOS
USANDO REDES NEURONALES ARTIFICIALES

POR

DAVID SOSA VALDES

EN OPCIÓN AL GRADO DE

INGENIERO EN TECNOLOGÍA DE SOFTWARE

SAN NICOLÁS DE LOS GARZA, NUEVO LEÓN

OCTUBRE 2015

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA

DIVISIÓN DE ESTUDIOS DE LICENCIATURA



SISTEMA DE RECONOCIMIENTO DE PATRONES EPILÉPTICOS
USANDO REDES NEURONALES ARTIFICIALES

POR

DAVID SOSA VALDES

EN OPCIÓN AL GRADO DE

INGENIERO EN TECNOLOGÍA DE SOFTWARE

SAN NICOLÁS DE LOS GARZA, NUEVO LEÓN

OCTUBRE 2015

Universidad Autónoma de Nuevo León

Facultad de Ingeniería Mecánica y Eléctrica

División de Estudios de Licenciatura

Los miembros del Comité de Tesis recomendamos que la Tesis «Sistema de reconocimiento de patrones epilépticos usando redes neuronales artificiales», realizada por el alumno David Sosa Valdes, con número de matrícula 1427614, sea aceptada para su defensa como opción al grado de Ingeniero en Tecnología de Software.

El Comité de Tesis

Dra. Satu Elisa Schaeffer

Asesor

Dr. César Guerra Torres

Revisor

Dr. Romeo Sánchez Nigenda

Revisor

Vo. Bo.

Dr. Arnulfo Treviño Cubero

División de Estudios de Licenciatura

San Nicolás de los Garza, Nuevo León, Octubre 2015

AGRADECIMIENTOS

A la Dra. Satu Elisa Schaeffer a la que considero como mi modelo a seguir. Aunque tuvimos incontables batallas en el transcurso de mi formación académica, ella siempre me brindó una educación de primer nivel y es por eso que siempre estaré agradecido por el tiempo, la atención prestada, sus consejos directos al punto crítico y especialmente por su paciencia en el transcurso de mi carrera profesional.

Quiero agradecer a mis padres Dora Elia Valdes Lozano y David Arturo Sosa Peralta que gracias a la formación que me dieron he podido concluir con mis estudios, siempre estaré agradecido por el apoyo incondicional que me brindan para resolver todos mis problemas personales o académicos en el transcurso de mi vida.

A mi novia Aydé Guadalupe González Ramírez que gracias a su apoyo pude terminar mis estudios.

Al Dr. Romeo Sánchez Nigenda y el Dr. César Guerra, integrantes de mi comité de revisores, cuyos comentarios y sugerencias fueron de gran ayuda para enriquecer el presente trabajo de tesis.

Al Dr. Claudio Muñoz y a los neurólogos del departamento de neurofisiología que apoyaron directamente con información y datos que son el insumo base de esta investigación y por su valiosa retroalimentación.

RESUMEN

David Sosa Valdes.

Candidato para el grado de Ingeniero en Tecnología de Software.

Universidad Autónoma de Nuevo León.

Facultad de Ingeniería Mecánica y Eléctrica.

Título del estudio:

SISTEMA DE RECONOCIMIENTO DE PATRONES EPILÉPTICOS USANDO REDES NEURONALES ARTIFICIALES

Número de páginas: 57.

OBJETIVOS Y MÉTODO DE ESTUDIO. El presente proyecto se desarrolla con el interés de aportar un modelo de predicción lo más preciso posible en las prácticas clínicas utilizando tecnologías de información. El objetivo es desarrollar un software que le permita al médico neurólogo diagnosticar con mayor eficiencia problemas epilépticos con rasgos característicos para poder avalar de forma cuantitativa criterios de evidencia que permitan realizar diagnósticos más eficientes.

Para realizar este proyecto es necesario recoger y procesar adecuadamente la información referente al estado de salud del paciente y controlarla con la evidencia acumulada

de otros pacientes en condiciones parecidas y controladas que permitan formar una base y así poder realizar un reconocimiento de patrones.

CONTRIBUCIONES Y CONCLUSIONES. La contribución principal de este trabajo está dirigido a dos disciplinas, una al desarrollo de la investigación de software y la otra al campo de la medicina en el área de la neurología. La aportación a la investigación de software se ubica en el desarrollo de un modelo de reconocimiento de patrones a través del uso de redes neuronales artificiales. Este modelo será utilizado para mejorar los diagnósticos médicos específicamente de la epilepsia del tipo Síndrome de West con lo que también se está aportando conocimiento a la clínica de la neurología.

El programa fue desarrollado y probado bajo ciertas condiciones experimentales. En lo que respecta al software se realizaron tres pruebas que demuestran la eficiencia y la precisión en la clasificación de señales. En lo que respecta al *hardware* se realizaron pruebas de rendimiento que demuestran la velocidad de procesamiento computacional.

Esta investigación puede ser considerada como un aporte al campo de la innovación en la medida en que sienta las bases para profundizar en el desarrollo de software para el diagnóstico médico de la epilepsia del tipo Síndrome de West en México ya que existen escasos antecedentes sobre el desarrollo de este tipo de herramienta.

Firma del asesor: _____

Dra. Satu Elisa Schaeffer

ÍNDICE GENERAL

1. Introducción	1
1.1. Motivación	2
1.2. Hipótesis y objetivos	2
1.3. Estructura de la tesis	3
2. Antecedentes	5
2.1. Actividades de la neurona	6
2.2. Señales	7
2.3. Electroencefalograma	8
2.4. Síndrome de West	10
2.5. Procesamiento de señales EEG	12
2.5.1. Transformada rápida de Fourier (TRF)	13
2.5.2. Transformada de Wavelet (TW)	13
2.6. Redes neuronales artificiales	14
2.6.1. Aprendizaje adaptativo	14

2.6.2. Organización automática	15
2.6.3. Tolerancia a fallos	16
2.6.4. Elementos básicos	16
3. Estado del arte	19
3.1. Revisión de trabajos relacionados	19
3.2. Análisis comparativo	21
3.3. Área de oportunidad	24
4. Solución propuesta	26
4.1. Metodología	27
4.1.1. Datos de entrada	27
4.1.2. Extracción de catacterísticas	29
4.1.3. Modelo LVQ	31
4.2. Implementación	32
4.2.1. Componentes de software	33
4.2.2. Arquitectura RNA	34
4.2.3. Inicialización	35
4.2.4. Regla de aprendizaje	35
4.2.5. Entrenamiento	36
5. Evaluación	38

5.1. Diseño experimental	38
5.1.1. Discriminación	40
5.1.2. Calibración	41
5.1.3. Desempeño	41
5.2. Resultados	42
5.2.1. Discriminación	43
5.2.2. Calibración	45
5.2.3. Desempeño	46
5.2.4. Rendimiento	48
6. Conclusiones	51
6.1. Discusión	52
6.2. Trabajo a futuro	53
Bibliografía	54

ÍNDICE DE FIGURAS

2.1. Estructura de una neurona	6
2.2. Amplitud de una señal	7
2.3. Frecuencia de una señal	8
2.4. Señales EEG	9
2.5. EEG: Sistema 10-20	10
2.6. Epilepsia	11
2.7. Neurona artificial	17
4.1. Reconstrucción del EEG	28
4.2. Extracción de características	30
4.3. Arquitectura LVQ	31
4.4. Arquitectura LVQ	34
5.1. Límites de discriminación	44

ÍNDICE DE CUADROS

3.1. Comparativa de trabajos	23
5.1. Análisis de discriminación.	45
5.2. Análisis de calibración.	46
5.3. Análisis de desempeño.	47
5.4. Análisis de desempeño.	48
5.5. Velocidad de procesamiento	49
5.6. Eficiencia de ejecución	50

CAPÍTULO 1

INTRODUCCIÓN

El Departamento de Neurología de la Universidad Autónoma de Nuevo León realiza investigación clínica en una gran cantidad de campos entre los cuales se encuentra la epilepsia y en especial el Síndrome de West (SW).

El SW o síndrome de los espasmos infantiles es un ataque epiléptico que se presenta en la infancia, es grave y poco frecuente. Siempre genera algún grado de retraso en el desarrollo infantil y a pesar de que el conocimiento sobre éste ha mejorado considerablemente, todavía hay casos en los que no se diagnostica a tiempo, sobre todo cuando los síntomas son leves o debido a la falta de experiencia por parte del médico especialista. Actualmente el diagnóstico de dicha enfermedad se realiza a través de análisis electroencefalográficos que el médico especialista interpreta para diagnosticar al paciente.

El Electroencefalograma (EEG) es un análisis que se utiliza para detectar diversos tipos de problemas en la actividad eléctrica del cerebro. Este procedimiento realiza un seguimiento de las ondas cerebrales y las registra. Por medio de un EEG, los médicos pueden buscar patrones anormales que indiquen convulsiones u otros problemas. Este procedimiento implica una importante inversión de tiempo y de recursos humanos. La inversión de tiempo y de recursos, además de la falta de medios que ayuden a realizar un diagnóstico eficiente constituye el problema del cual parte esta investigación.

En esta investigación se pretende desarrollar una aplicación tecnológica que pueda detectar o predecir patrones epilépticos del tipo SW en los análisis electroencefalográficos que pueda ayudar al neurólogo a tener una evidencia que le ayude a detectar o diagnosticar de una manera eficiente y segura.

1.1 MOTIVACIÓN

El proceso de generación de señales eléctricas por parte de las neuronas todavía no ha sido comprendido completamente. Las señales del cerebro se caracterizan por no ser estacionarias¹ e incluso podrían no ser lineales², por lo que analizar estas señales y generar modelos de predicción puede aportar información de interés hacia los médicos especialistas a la hora de realizar una investigación clínica.

Dentro de las posibles alternativas disponibles que existen en la actualidad, las redes neuronales artificiales (RNA) se utilizan cada vez más dentro del área de medicina. Tienen el propósito de apoyar al médico en el diagnóstico y el tratamiento del paciente.

1.2 HIPÓTESIS Y OBJETIVOS

La presente tesis se basa en la siguiente *hipótesis*: Existe un patrón epiléptico definido del tipo SW que puede detectarse en las señales electroencefalográficas a través de la RNA.

El *objetivo general* es diseñar un *software* que permita diagnosticar con mayor eficiencia ataques epilépticos del tipo SW usando una RNA.

Los *objetivos específicos* son:

¹Las señales estacionarias son aquellas señales en las cuales, ciertos puntos de la señal permanecen inmóviles.

²Las señales lineales son aquellas que se propagan a lo largo de una sola dirección del espacio. Si la señal se propaga en una dirección única, sus frentes de onda son planos y paralelos.

1. Crear un *software* que pueda procesar las señales electroencefalográficas obtenidas de análisis electroencefalográficos.
2. Crear un *software* que pueda detectar patrones epilépticos del tipo SW en análisis electroencefalográficos usando RNA.
3. Crear una herramienta que le permita al médico especialista visualizar el resultado del procesamiento de las señales. Dicha herramienta también debe de poder predecir un ataque epiléptico que el paciente pueda presentar.

1.3 ESTRUCTURA DE LA TESIS

El presente trabajo de tesis está organizado de la siguiente manera. En el capítulo dos se desarrollan los antecedentes que ubican al lector en el objeto principal de estudio, se toman en cuenta algunos aspectos que el lector necesita conocer antes de proseguir con los siguientes capítulos. En el capítulo tres se habla al respecto de los trabajos relacionados usados como referencias de esta investigación, gran parte del interés del lector puede surgir en este capítulo debido a que también se le da a conocer el área de oportunidad de esta investigación de forma comparativa con respecto a las demás.

En el capítulo cuatro se ve a detalle la solución propuesta con la cual se resalta el interés de realizar una innovación en el campo de la medicina y en conjunto con la ingeniería de *software*. Cabe destacar que en este capítulo se describe paso a paso la metodología y planeación seguida, los materiales usados para los experimentos e inclusive algunas dificultades que se presentaron a la hora de realizarlos.

En el capítulo cinco se analizan los resultados experimentales obtenidos a lo largo del proceso de desarrollo de *software*. Este capítulo en particular es sumamente

importante debido a que la evaluación de los experimentos da como resultado la validación de este estudio. Por último, en el capítulo seis se realizan las conclusiones y el trabajo a futuro mencionado.

CAPÍTULO 2

ANTECEDENTES

La presente investigación abarca tanto áreas de la medicina neurológica como la ingeniería de software. En primera instancia se describen algunos conceptos relacionados con la estructura y funcionamiento del cerebro humano. Después se desarrollan conceptos matemáticos que son necesarios para comprender e interpretar los datos experimentales que posteriormente se procesarán y analizarán para avalar la solución propuesta de este proyecto. Luego se presentan las herramientas de desarrollo tanto de software como de *hardware* que son utilizadas en este estudio.

Dentro de las herramientas de desarrollo de software se usan conceptos de programación de los lenguajes Python¹ y R². La principal herramienta de *hardware* utilizada fue el EEG para la medición de las señales eléctricas producidas por el cerebro.

Por último se describe el modelo de inteligencia artificial RNA según Walczak y Nowack [17], quienes fueron los primeros en realizar un estudio completo utilizándolo en el diagnóstico de la epilepsia.

¹Sitio oficial de Python <https://www.python.org/>

²Sitio oficial de R <http://www.r-project.org/>

2.1 ACTIVIDADES DE LA NEURONA

Existen dos tipos de células en el sistema nervioso central: las células nerviosas y las células glía. Las células nerviosas consisten en un conjunto de axones, dendritas y cuerpos celulares. Los axones que tienen una forma cilíndrica transmiten impulsos eléctricos. Las dendritas están conectadas a los axones, dendritas o a otras células y reciben impulsos eléctricos. Cada nervio está conectado aproximadamente a otros 10,000 nervios. La actividad eléctrica se debe principalmente al flujo de corriente entre la punta de las dendritas y axones de las células.

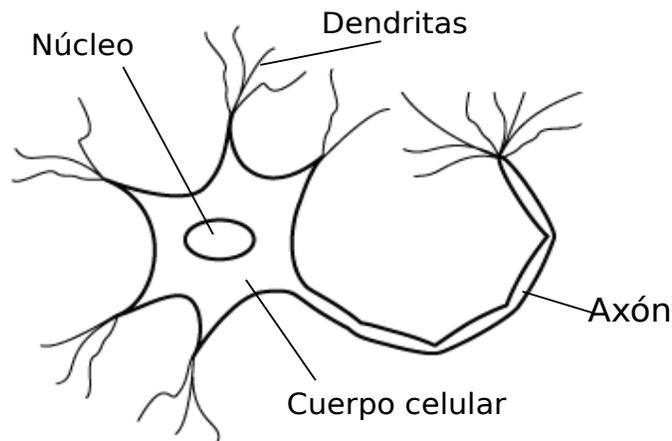


Figura 2.1 – Estructura de una neurona.

El proceso de esta actividad comienza cuando la neurona recibe un estímulo el cual provoca un impulso nervioso que pasa a través del axón hasta llegar a los conductos que transmiten a su vez una señal. Estas señales son uno de los principales elementos para entender el modo de funcionamiento del cerebro humano.

2.2 SEÑALES

Una señal es una variación en el tiempo o el espacio de una magnitud³ física. Contiene información sobre la conducta de algún tipo de fenómeno. Aunque las señales pueden representarse en muchas formas, en todos los casos la información de una señal esta contenida en un patrón que varía de alguna manera. Para determinar algún patrón en una señal primero debemos medir su amplitud y frecuencia con respecto al tiempo.

La amplitud es la medida de la variación máxima del desplazamiento con respecto al tiempo. Para determinar la amplitud de una señal se debe de obtener la distancia desde el punto más alto de la señal hasta la base.

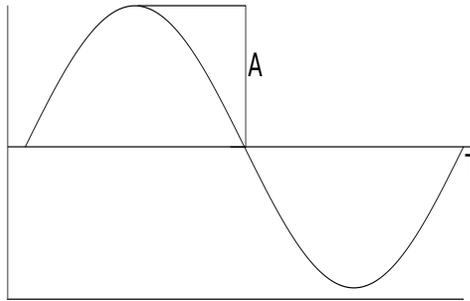


Figura 2.2 – La amplitud (A) de una onda determinada por el punto más alto hasta la base con respecto al tiempo (T).

La frecuencia es una magnitud que mide el número de repeticiones que ocurren en un instante de tiempo. Para determinar la frecuencia en una señal es necesario saber cuál es su longitud de onda. La longitud de onda se determina por la distancia entre dos crestas⁴ o dos valles⁵ consecutivos.

Las señales provenientes del cerebro se pueden medir de manera no invasiva por

³Una magnitud es toda propiedad de los cuerpos que se puede medir. Por ejemplo: temperatura, velocidad, masa, peso, etc.

⁴La cresta es el punto más alto de una onda.

⁵El valle es el punto más bajo de una onda.

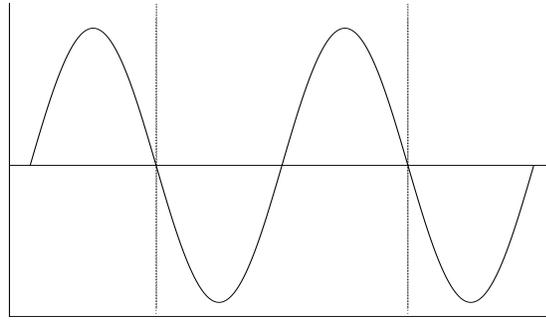


Figura 2.3 – La distancia entre dos crestas o dos valles es la longitud de onda.

medio de diversas herramientas. El médico especialista analiza e interpreta estas señales para proporcionar un diagnóstico oportuno y correcto, que a su vez, le permitirá administrar el tratamiento correcto de medicamentos y también ofrecer un pronóstico.

2.3 ELECTROENCEFALOGRAMA

El EEG es examen de exploración indolora que estudia la actividad eléctrica producida en el cerebro. El examen lo realiza un técnico especialista en electroencefalografías en un consultorio médico, en un hospital o en un laboratorio. Para poder realizar un EEG es necesario colocar unos discos metálicos planos, llamados electrodos, en diferentes zonas de la cabeza, que corresponden a las áreas del cerebro las cuales permiten que se transmitan las señales eléctricas cerebrales desde los cables que van implantados en los electrodos hasta la computadora.

En la figura 2.4 se muestra un ejemplo de como el EEG le permite al médico especialista visualizar la actividad cerebral del paciente. Debido a que se realizan diversas actividades durante el análisis completo los resultados pueden variar, tales actividades involucran la respiración profunda, movimientos del cuello o mirar hacia una luz muy brillante y centellante.

El procedimiento para realizar un EEG es muy seguro, sin embargo, las luces deslumbrantes o la respiración rápida requeridas durante el examen pueden desencadenar convulsiones en aquellas personas con trastornos convulsivos. El médico que lleva a cabo la electroencefalografía está capacitado para cuidar del paciente si esto sucede.



Figura 2.4 – Ejemplo de las señales capturadas por el EEG por cada electrodo conectado al cerebro.

El Sistema 10-20 mostrado en la figura 2.5 presenta un orden sistemático para ubicar los electrodos cerebrales durante la adquisición de la señal de EEG. Su nombre proviene de la forma en la que estos electrodos se encuentran ubicados a distancias de 10 y 20 por ciento entre tres secciones de la cabeza; inión, que corresponde a la protuberancia en el medio de la parte posterior de la cabeza, nasión, que es el puente de la nariz directamente debajo de la frente y el punto preauricular, el cual es la depresión del hueso al frente de cada canal auditivo. La ubicación de cada electrodo está marcada por una letra, la cual corresponde a la región cerebral en la cual está ubicada y un número que corresponde a su desplazamiento lateral. La localización correcta de los electrodos en el cuero cabelludo es de alta importancia para garantizar la obtención de señales verídicas según lo que se esté buscando al

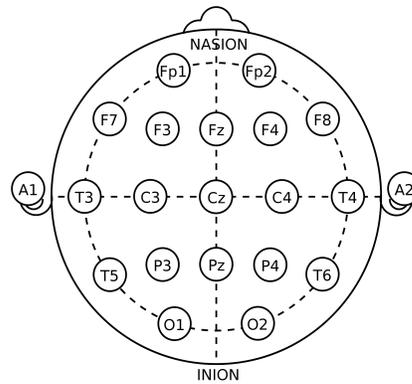


Figura 2.5 – El sistema 10-20 indica la posición de los electrodos en el paciente.

realizar la EEG.

Hay diferentes maneras de contaminar una señal eléctrica. En el caso de las señales cerebrales se presenta en todo momento ruido de fondo en la actividad neuronal, y artefactos tanto de origen biológico o por una fuente externa no necesariamente relacionada con la actividad cerebral. El mismo organismo, produce un sinnúmero de respuestas durante todo el tiempo que pueden ser captadas por los electrodos durante la toma de las señales; entre éstas se encuentran el movimiento ocular y el parpadeo, lo cual representa una actividad continua que se traduce en ruido contaminante.

Para realizar un análisis clínico de las señales EEG se examinan diversas propiedades que éstas poseen, tales como: la forma de la onda, la frecuencia, la amplitud, la relación de fase, entre otras.

2.4 SÍNDROME DE WEST

Las señales que provienen de la actividad neuronal de diversas zonas en el cerebro son la manifestación de millones de operaciones voluntarias e involuntarias que el cerebro se encarga de regular para que nuestro cuerpo funcione correctamente. A veces, se vuelven irregulares y esto da lugar a una convulsión. Las convulsiones son uno de los elementos que caracterizan a la epilepsia.

La epilepsia es un trastorno del sistema nervioso central en el que se alteran las células nerviosas en el cerebro causando convulsiones. El SW es un tipo de epilepsia que se presenta en la infancia por lo general entre los 4 y 10 meses de edad. De entre las principales características del SW la hipsarritmia es una evidencia fundamental para diagnosticar este tipo de síndrome.

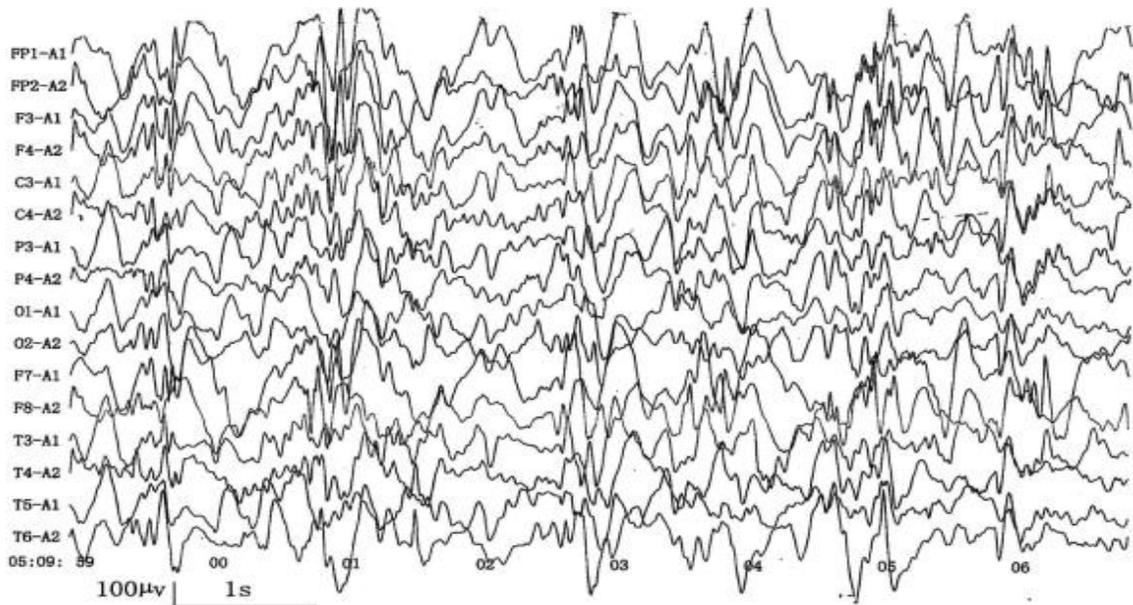


Figura 2.6 – Ejemplo de las señales capturadas por el EEG cuando el paciente sufre de ataques epilépticos.

La hipsarritmia es un patrón interictal⁶ en las señales eléctricas del cerebro. Representa un trastorno convulsivo con características clínicas y electroencefalográficas únicas, los síntomas que presenta el paciente son la epilepsia intratable crónica y el retraso psicomotor; la incidencia se considera que es de 16 a 42 por 1000 nacidos [7]. Durante el sueño lento, este patrón se muestra a menudo como ondas lentas irregulares separadas por períodos de disminución eléctrica con un registro pobremente organizado.

Para poder realizar un análisis clínico que demuestre que un paciente tiene SW se requiere que un neurólogo realice una exploración visual para determinar cualitativamente que el caso se presente; sin embargo, esto resulta bastante difícil debido a que

⁶Interictal: relativo o perteneciente al período de tiempo entre los ataques de un trastorno.

extraer características de la información que proporcionan las señales EEG a simple vista puede llegar a ser impreciso y se invierte demasiado tiempo. Es por eso que procesos autónomos y nuevos métodos estadísticos deben encargarse de procesar los componentes de estas señales.

2.5 PROCESAMIENTO DE SEÑALES EEG

El procesamiento de las señales tiene como fin permitir la extracción de la información relevante de estas, eliminando los componentes que corresponden a ruido contaminante o que no son de importancia para el cumplimiento del objetivo para el cual estas señales fueron tomadas.

Todo el tiempo, las neuronas generan diferentes impulsos, las cuales pueden dividirse en los cuatro grupos que se presentan a continuación:

Ondas alfa. Son ondas comprendidas entre los 8 a los 13 Hz. Tienen una amplitud moderada y están asociadas a la vigilia relajada.

Ondas beta. Estas ondas poseen una amplitud menor y se distribuyen entre los 13 y los 30 Hz. La aparición de estas ondas se relaciona con estados de actividad mental intensa.

Ondas delta. Son ondas que tienen mayor amplitud, se encuentran entre los 0.5 y los 4 Hz.

Ondas teta. Las ondas theta están entre los 4 y 7 Hz.

Ondas gama. Este tipo de ondas pueden reconocerse en un rango de 25 Hz a 100 Hz durante la percepción consciente del paciente.

En el caso de las bioseñales o señales biológicas, procesarlas se traduce en asociar a estas un estado patológico⁷ del cuerpo, describir un comportamiento o realizar un seguimiento del funcionamiento corporal.

2.5.1 TRANSFORMADA RÁPIDA DE FOURIER (TRF)

Durante el procesamiento de señales puede ser de utilidad analizar frecuencias por separado. La transformada rápida de Fourier (TRF) es una operación matemática que convierte una señal al dominio del tiempo mediante la obtención y filtración de cada uno de sus componentes.

No es una operación que altere la señal sino que simplemente la muestra en un nuevo dominio. Es algo así como una nueva forma de ver la misma señal, pero que va a tener usos muy intuitivos no disponibles en su estado original que facilitarán el aprendizaje de ciertas características de dicha señal.

La TRF se define mediante la siguiente formula. Se asume que $N = 2^r$ donde N es un entero positivo, j es la muestra actual, h_j es el valor de la señal en el tiempo j , k es la frecuencia actual y r es una señal discreta:

$$H_k = \sum_{j=0}^{N-1} h_j W^{jk}, \quad \text{donde } W = e^{\pm \frac{2\pi i}{N}}. \quad (2.1)$$

2.5.2 TRANSFORMADA DE WAVELET (TW)

La TW es una técnica usada para el análisis de señales y, al igual que la TRF, convierte una señal al dominio del tiempo. La diferencia está en que la TW provee análisis de multiresolución, los cuales consisten básicamente en aproximar una

⁷La patología es el estudio científico de las enfermedades; describe la causa, la evolución y el termino de una enfermedad y la naturaleza de sus lesiones, basándose en observaciones precisas seguidas por deducciones lógicas.

función $f(t)$ en distintos niveles de resolución. Cabe destacar que con la TW se logra discriminar las señales que tengan frecuencias bajas y frecuencias altas, y a su vez determinar el grado de detalle de la señal y de aproximación de la misma:

$$WTx(\tau, a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t)h * \left(\frac{t - \tau}{a}\right)dt. \quad (2.2)$$

Para realizar un proceso de reconocimiento de patrones epilépticos es necesario implementar un modelo que permita analizar un gran conjunto de datos que no representen alguna medida que pueda definirse como un patrón.

2.6 REDES NEURONALES ARTIFICIALES

Una RNA es un algoritmo de cálculo que se basa en una analogía del sistema nervioso del ser humano. La idea general consiste en emular la capacidad de aprendizaje que este sistema utiliza, de manera que la RNA aprenda a identificar un patrón entre los valores de un conjunto de variables seleccionadas conocidas como entradas y los estados que se consideran dependientes de dichos valores conocidos como salidas.

Algunas de las características más importantes que presentan las RNA es que son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de extraer o abstraer las características esenciales de las entradas aprendidas, entre otras cosas. A continuación se menciona un listado de las características que representan de más utilidad destacar para el presente estudio.

2.6.1 APRENDIZAJE ADAPTATIVO

Como las RNA pueden aprender a diferenciar patrones mediante ejemplos y entrenamientos, no es necesario elaborar modelos o especificar funciones de distribución

de probabilidad debido a que son sistemas dinámicos que se adaptan automáticamente. Por una parte son adaptables debido a la capacidad ajuste automático de sus elementos internos llamados neuronas que componen este sistema. Por otra parte son dinámicos porque son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones.

En el proceso de aprendizaje, los enlaces o conexiones que existen entre estas neuronas se ajustan de manera que se obtengan ciertos resultados específicos. Una RNA no necesita un algoritmo para resolver un problema, ya que ella puede generar su propia distribución de pesos en los enlaces mediante el aprendizaje repetitivo. La mayoría de las veces continúan aprendiendo a lo largo de su vida, después de completado su período de entrenamiento.

2.6.2 ORGANIZACIÓN AUTOMÁTICA

Las RNA emplean su capacidad de aprendizaje adaptativo para organizar automáticamente la información que reciben durante el aprendizaje y la operación. La organización automática consiste en la modificación que la RNA completa para llevar a cabo un objetivo en específico. Esto provoca la generalización⁸. El sistema puede generalizar la entrada para obtener una respuesta. Esta característica es importante cuando se tiene que solucionar problemas en los cuales la información de entrada no es del todo clara; además permite que el sistema de una solución o respuesta, incluso cuando la información de entrada está especificada de forma incompleta.

⁸Generalización es la facultad de las RNA para responder apropiadamente cuando se les presentan datos o situaciones a las que no había sido expuesta anteriormente.

2.6.3 TOLERANCIA A FALLOS

Las RNA fueron los primeros métodos computacionales con la capacidad de tolerancia de fallos, comparados con los sistemas tradicionales, los cuales pierden su funcionalidad cuando sufren un pequeño error de memoria. En las RNA, si se produce un fallo en un número no muy grande de neuronas y aunque el comportamiento del sistema se ve influenciado por este fallo o error, no sufre una caída repentina.

Hay dos aspectos distintos respecto a la tolerancia a fallos:

- Pueden aprender a reconocer patrones con ruido, distorsionados o incompletos.
- Pueden seguir realizando su función aunque se destruya parte de la red.

La razón por la que las RNA son tolerantes a los fallos es que tienen su información distribuida en todas las conexiones que existen entre sus neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento. Esta información que almacena hace que la mayoría de las conexiones entre las neuronas tendrán sus valores en función de los estímulos recibidos en esas conexiones, y se generará un patrón de salida que represente esa información almacenada.

2.6.4 ELEMENTOS BÁSICOS

Desde el punto de vista de implementación práctica, las neuronas, también llamados nodos, son objetos simples que emulan la respuesta de una neurona real para un determinado estímulo. Estos elementos, como las neuronas en el sistema nervioso, funcionan como interruptores: cuando la suma de señales de entrada es suficientemente alta, la neurona manda una señal a las neuronas con las que mantiene una conexión, a esta acción la conocemos como potencial de acción. Esta situación se modela

matemáticamente como la suma de pesos de todas las señales de llegada al nodo que se compara con un umbral característico aproximado a la respuesta deseada.

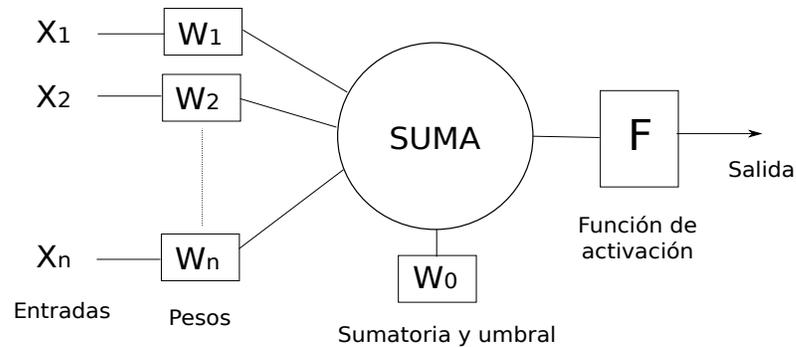


Figura 2.7 – Neurona artificial basada en el modelo biológico.

Si el umbral se supera, entonces el nodo se activa, mandando una señal a otras neuronas, que a su vez procesarán esa información en conjunto con la que reciben de neuronas adyacentes⁹. Evidentemente, la respuesta de cada neurona dependerá del valor de las interacciones con otras neuronas dentro de su estructura. Como en el caso del sistema nervioso, el poder computacional de una RNA deriva no de la complejidad de cada unidad de proceso, sino de la densidad y complejidad de sus interconexiones. Es decir que mientras más conexiones haya dentro de la RNA es mayor el poder computacional que consume.

El conocimiento acumulado por la RNA se distribuye en sus numerosas conexiones, esto tiene como consecuencia la tolerancia a fallos y la eliminación de ruidos, lo cual hace que sea capaz de seguir funcionando adecuadamente a pesar de sufrir lesiones en sus conexiones por datos incompletos. En un programa tradicional un pequeño fallo en cualquier punto puede invalidarlo todo y dar un resultado absurdo o no dar ningún resultado. Estos problemas no se ven presentes en una RNA porque

⁹Las neuronas que se encuentran una junto a la otra, es decir, en el mismo conjunto de una capa de la RNA se les conoce como nodos adyacentes.

conserva la eliminación del ruido y la tolerancia a fallos después de haber adquirido el conocimiento mediante el aprendizaje.

Al igual que en el sistema nervioso humano, el conocimiento se encuentra en los pesos de las conexiones entre neuronas, y no en las neuronas en sí. Estos pesos no tienen valor constante, sino que van variando en función de un determinado algoritmo, denominado regla de aprendizaje. Una regla de aprendizaje hace variar el valor de los pesos de una RNA hasta que estos adoptan un valor constante, cuando ello ocurre se dice que la red ya ha aprendido.

En la literatura consultada se mencionan diversas reglas de aprendizaje utilizadas, las cuales pueden dividirse en dos grandes grupos:

Aprendizaje supervisado. Cuando existe una entrada o muestra de información que sirve de ejemplo para que la RNA aprenda.

Aprendizaje no supervisado. Cuando no existe algún precedente de información relevante y los pesos de la RNA cambian constante y libremente sin ningún tipo de referencia, hasta que llegan a un punto de equilibrio al cual intentan adaptarse.

Como se ha mencionado, es posible interactuar con la información de manera diferente por cada caso existente; es por eso que el utilizar este método demanda una gran cantidad de experimentación y análisis estadístico para poder garantizar un descubrimiento de algún patrón.

CAPÍTULO 3

ESTADO DEL ARTE

En esta sección se reportan las investigaciones realizadas en el ámbito internacional a partir de los últimos diez años, relacionadas con temas de procesamiento de señales, las RNA, el reconocimiento de patrones y los desarrollos de métodos alrededor del diagnóstico de la epilepsia del tipo SW.

En la primera sección se discuten los trabajos que tiene relación con la investigación propuesta y se describen brevemente que abarcan cada uno de los temas. En la segunda sección se destacan las características utilizadas para poder realizar una comparación. Por último se identifican las áreas de oportunidad teóricas y metodológicas que permiten establecer los puntos de partida de esta investigación

3.1 REVISIÓN DE TRABAJOS RELACIONADOS

Hasta el día de hoy, una gran cantidad de técnicas se han propuesto para el procesamiento y la extracción de señales EEG que presenten patrones epilépticos y la precisión de la clasificación ha sido reportada. A continuación se presentan algunos ejemplos.

La primera implementación del modelo RNA específicamente para el diagnóstico de la epilepsia se describe en los trabajos de Walczak y Nowack [17]. Ellos descubrieron que

las características de las formas epilépticas pueden ser usadas para realizar discriminaciones y patrones específicos. Estos factores pueden ser cruciales y contribuyen una información importante para realizar una mejor interpretación del estudio realizado con el EEG y mejorar el cuidado de los pacientes. Sus estudios evalúan la eficacia del uso de las RNA para modelar las relaciones que existen entre las convulsiones y variables cualitativas específicas medidas con el EEG.

Lee et al. [10] propusieron clasificar convulsiones normales y epilépticas de señales EEG utilizando tres métodos de pre-procesamiento combinados: la transformada de Fourier, la reconstrucción de la Fase-Espacio y la distancia Euclidiana para la extracción de las características de la señal y utilizarlas en una red neuronal NEWFM¹. Ellos concluyeron que las diferencias entre una convulsión normal y epiléptica para una entrada de 24 características se puede visualizar y analizar para detectar patrones relacionados.

Por otra parte, los trabajos teóricos de Zuhair et al. [18] y la aportación sobre redes auto-organizadas de Kohonen et al. [8] proporcionaron nuevas aportaciones a este tipo de técnica.

Pradhan et al. [13] determinaron la eficiencia que una RNA tiene al clasificar y detectar descargas epilépticas utilizando el modelo LVQ. Ellos concluyeron que debido a ciertos casos de tipo falso-positivo se requirieron de más pruebas con análisis clínicos para que se pudiera evaluar esencialmente la generalización que proporcionaba la RNA; sin embargo, la importancia que ellos resaltaron es que la RNA LVQ presenta una gran cantidad de ventajas; tales como su fácil adaptación, tanto individualmente para algún caso general o alguna situación clínica específica; su implementación y entrenamiento con grandes vectores de entrada sin necesidad de algún tipo de

¹NEWFM: llamada así por sus siglas en inglés Neural Network Fuzzy Membership; este tipo de red neuronal es muy conocida por ofrecer un excelente rendimiento en la predicción y clasificación de señales EEG epilépticas.

pre-procesamiento o parametrización y su entrenamiento supervisado que le brinda mucha flexibilidad.

A partir de estos trabajos pioneros, el interés sobre esta metodología se ha difundido a muchas ramas de la ciencia. Los distintos aspectos técnicos y las implicaciones de su utilización han sido investigados desde muchos puntos de vista, interesando entre otros, a matemáticos, físicos, neurólogos, ingenieros, programadores y filósofos.

3.2 ANÁLISIS COMPARATIVO

A partir de la literatura consultada se pudieron encontrar rasgos o características equivalentes en el proyecto presentado en esta tesis. En el cuadro 3.1 se puede apreciar una tabla comparativa que demuestra los proyectos que presentan estas características y se resaltan aquellas que se quiere alcanzar. Las características a evaluar en los proyectos considerados se eligieron de acuerdo a los objetivos y metas que se quieren alcanzar en el proyecto actual y que se consideran de importancia por ser innovadoras en el campo de la inteligencia artificial. A continuación se presentan dichas características:

Procesamiento. El sistema utiliza una o más técnicas de procesamiento de señales para los datos extraídos del EEG.

Clasificación. El sistema realiza clasificación o selección de datos de entrada.

Entrenamiento supervisado. El modelo RNA del sistema realiza un entrenamiento de tipo supervisado.

Discriminación. Se cuenta con una discriminación para evaluar el resultado de la clasificación obtenida.

Modelo LVQ. La RNA usa un modelo LVQ para la detección de la epilepsia.

Multi-capas. La RNA cuenta con más de una capa que pueden o no pueden tener un modelo RNA diferente al inicial.

Epilepsia SW. El sistema realiza una clasificación de señales epilépticas del tipo SW.

El sistema desarrollado en el presente trabajo incluye todas las características mencionadas en esta sección. Una de las principales características destacadas es la intención de encontrar un modelo que permita realizar una detección de señales epilépticas que permitan diagnosticar con una mayor precisión el SW utilizando RNA con un entrenamiento no supervisado para facilitar dicho estudio. El proyecto está enfocado en uno de muchos tipos de ataques epilépticos que se han detectado actualmente, por lo cual, es factible destacar que el enfoque realizado presenta una comparativa con datos de entrada de diferentes tipos de epilepsia para comparar la efectividad de la detección y la clasificación que la RNA brinda.

Cuadro 3.1 – Cuadro comparativo de trabajos relacionados.

Trabajo	Procesamiento	Clasificación	Entrenamiento supervisado	Discriminación	Modelo LVQ	Multi-capas	Epilepsia SW
Uldry et al. [16]	✓	✓	✗	✗	✗	✗	✗
Harikumar et al. [6]	✓	✓	✗	✗	✗	✗	✗
Zuhair et al. [18]	✓	✓	✓	✗	✗	✓	✗
Lee et al. [10]	≈	✓	✓	✓	≈	✗	✗
Chatterjee et al. [3]	✓	✓	✗	✓	✗	✗	✗
Sahin et al. [14]	✓	✓	✓	✗	✗	✗	✗
Gao et al. [5]	✓	✗	✗	✗	✓	✗	✗
Marchena et al. [11]	✓	✓	✓	✗	✗	✗	✗
Chatterjee et al. [3]	✗	✓	✗	✓	✓	✓	≈
Harikumar et al. [6]	✓	✓	✗	✓	✗	✗	≈
Propuesta de tesis	✓	✓	✓	✓	✓	✓	✓

✓ - Implementado ✗ - No implementado ≈ - Parcialmente implementado

3.3 ÁREA DE OPORTUNIDAD

El análisis de tiempo y frecuencia al parecer es una parte fundamental de su técnica para la extracción de características en las señales EEG por lo que resulta de interés para la construcción de la técnica que se utilizará en esta investigación.

Sobre el procesamiento de señales, las investigaciones revisadas reportan una gran diversidad de métodos de procesamiento de señales que permiten llegar a resultados para la clasificación de señales epilépticas. Para esta investigación en particular se usarán la TW y FFT para el análisis de frecuencias.

Todas las investigaciones revisadas toman en cuenta separar las entradas en períodos o fragmentos de los análisis obtenidos con el EEG, en la mayoría de ellos se menciona un periodo de entre veinte y tres y cien segundos para realizar un procesamiento de señales y reconocimiento de patrones acertados; ellos concluyen que con esta clasificación se puede diagnosticar eficientemente. También otro factor importante es el mencionar la cantidad de neuronas que se usa para una RNA, existe un promedio entre nueve y veinte neuronas que ellos mencionan; esto se tomará en cuenta para la investigación.

Se ha comprobado en la literatura que el modelo RNA LVQ no implementa métodos de pre-procesamiento debido a su clasificación supervisada. Dicho modelo combinado con el análisis de tiempo y frecuencia será expuesto a experimentación para verificar su eficiencia de aprendizaje y nivel de clasificación.

Como se analizó en esta sección, muchas técnicas se han usado para obtener representaciones y extraer características de interés para la clasificación de las señales EEG epilépticas, sin embargo, solo algunas han concentrado sus estudios en el reconocimiento de patrones epilépticos del tipo SW por lo que la presente tesis tiene su foco

de interés en el desarrollo de un sistema que permita llegar a una herramienta de software para identificar o diagnosticar este síndrome.

CAPÍTULO 4

SOLUCIÓN PROPUESTA

El objetivo principal de este trabajo fue el de implementar una técnica para diagnosticar con mayor eficiencia los ataques epilépticos del tipo SW usando una RNA. Para poner a prueba la hipótesis propuesta se creó un software que tiene la capacidad de clasificar y aprender a base de entrenamiento; para ello se establecieron los lenguajes de programación usados y las librerías necesarias que incluyan las funciones que permitieron el desarrollo del mismo.

Así mismo se realizó una especificación técnica de los requisitos de *hardware* para que la aplicación de software funcione correctamente, así como el equipo médico usado para obtener los análisis clínicos utilizados como entradas clasificables y la forma en que se conectan todos estos componentes para realizar un estudio completo. Se definieron todos los procesos necesarios para realizar el objetivo principal de esta investigación, tales como la arquitectura usada para la RNA, el modelo a seguir para realizar una clasificación de patrones neurológicos, la regla de aprendizaje, el entrenamiento impuesto que seguirá la RNA y por último la forma de representar dicha información para que sea analizada posteriormente.

La implementación de este software se divide en tres etapas; datos de entrada, que consiste en aclarar la forma en la que es usada la información extraída del EEG; la extracción de características de las señales del EEG, que consiste en la selección

de los elementos que son de utilidad o por decirlo de una manera simple, los datos usados para el entrenamiento de la RNA; y la arquitectura de la RNA, que consiste explicar el proceso de construcción del modelo propuesto que permite identificar patrones de comportamiento en las señales para diagnosticar la epilepsia SW.

4.1 METODOLOGÍA

Una metodología sostiene que un conjunto de elementos tales como procesos, herramientas utilizadas y procedimientos pueden ser utilizados para alcanzar cierto objetivos que rigen una investigación. En esta sección se describe la metodología a utilizar para el desarrollo del presente trabajo de tesis.

4.1.1 DATOS DE ENTRADA

El presente estudio se realiza con dieciséis casos clínicos clasificados con epilepsia en general, nueve de los cuales son tipo SW. Estos casos fueron proporcionados por el Departamento de Neurología de la Universidad Autónoma de Nuevo León los cuales fueron la base para la implementación de este estudio.

Para realizar este procedimiento se usó la librería de Python Fileinput¹ debido a que estos archivos llevan información grabada en un período mayor a los 30 minutos. Usar esta librería representa una lectura eficiente para poder procesar los datos de entrada.

Los casos clínicos fueron separados en dos grupos: epilepsia normal y SW. Cada caso corresponde a un archivo que reporta las mediciones cuantitativas resultado del análisis elaborado con el EEG. Cada archivo contiene 325,000 entradas en promedio,

¹Fileinput: este módulo implementa una clase y funciones auxiliares para escribir rápidamente un ciclo sobre la entrada de archivo o una lista de archivos.

dependiendo del caso en específico; 23 columnas que corresponden a los 23 electrodos conectados a la cabeza del paciente. Estos datos fueron obtenidos con una máquina EEG convencional (Nohon Kohden). Las condiciones de grabación siguen la guía número siete de la Sociedad Americana de EEG. Los electrodos fueron puestos siguiendo el sistema internacional 10-20. Las señales obtenidas del EEG fueron amplificadas para registrar su sensibilidad para su digitalización y se obtuvieron a través de un filtro Butterworth de cuarto orden de paso de banda y se repitió dos veces en forma de cascada. Dicho filtro removi6 la mayoría del ruido encontrado en la se1al. Se encontr6 que los datos filtrados son adecuados para realizar una posible clasificaci6n, lo que se comprob6 con el an1lisis visual realizado por los neur6logos.

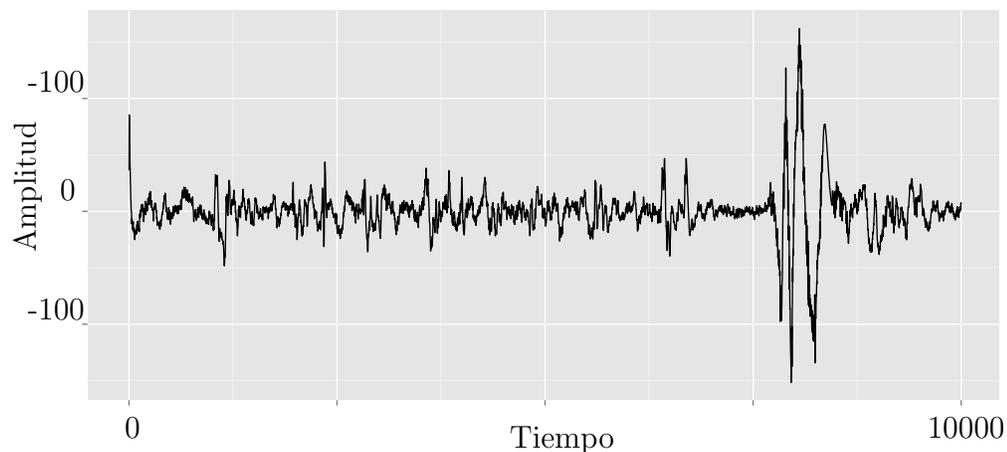


Figura 4.1 – Im1gen reconstruida del electrodo n1mero uno en los primeros segundos grabados.

Las se1ales fueron segmentadas en per6odos de 1000 segundos de duraci6n para ser evaluadas por los neur6logos. Con esta labor se seleccionaron los registros de entrenamiento. Cabe destacar que dichos casos fueron realizados en per6odos fuera del tiempo de investigaci6n, por lo cual fue imposible el poder detectar artefactos en las se1ales para poder excluirlos y solamente se tomaron en cuenta los per6odos que representan una gran importancia para clasificar correctamente la epilepsia SW.

Cabe destacar que se realizaron estudios cl6nicos de diversos pacientes para conformar

una base de datos que sirvió para que la RNA tuviera la suficiente información preliminar del patrón SW y darle una mayor precisión a la hora de clasificar estas señales.

4.1.2 EXTRACCIÓN DE CATACTERÍSTICAS

El procesamiento de las señales tiene como fin permitir la extracción de la información relevante de éstas, eliminando los componentes que corresponden a ruido o que no son de importancia para el cumplimiento del objetivo. Las señales transmiten información y procesarlas es encontrar entre esa información los segmentos de interés y relevancia. Para utilizar una buena clasificación es necesario realizar métodos heurísticos² y de regularización³. Con una clasificación de datos es posible comparar los diferentes análisis clínicos de los pacientes que presenten una hipsarritmia, debido a que las características de la hipsarritmia puede ser encontrada de diversas formas en las señales eléctricas se debe de realizar un algoritmo de reconocimiento de patrones, en el que los datos procesados se analicen para buscar zonas de interés. En esta sección se explica el proceso de separación de entradas en épocas para poder detectar los patrones epilépticos.

Con las señales EEG exportadas en archivos se procede a realizar el proceso de separación, el cual consiste en dividir el total de entradas en épocas de 20 segundos por cada uno de los canales del EEG. Para realizar este procedimiento se eligió el lenguaje de programación R, que es un lenguaje de código abierto⁴ y facilita la lectura de archivos así como las operaciones conjuntas que se realizaron en la fase inicial del

²El método heurístico se basa en el sentido común o la experiencia de los investigadores para determinar la solución a un problema de forma directa.

³En un método de regularización una constante es impuesta como parámetro para realizar la clasificación.

⁴El código abierto es el software distribuido bajo una licencia que permite su uso, modificación y redistribución. El requisito principal es que el código fuente se encuentre disponible para estudiar el funcionamiento del programa y efectuar modificaciones con el fin de mejorarlo y/o adaptarlo a algún propósito específico.

desarrollo de software de este proyecto.

En la figura 4.2 se muestra un diagrama del funcionamiento del software.

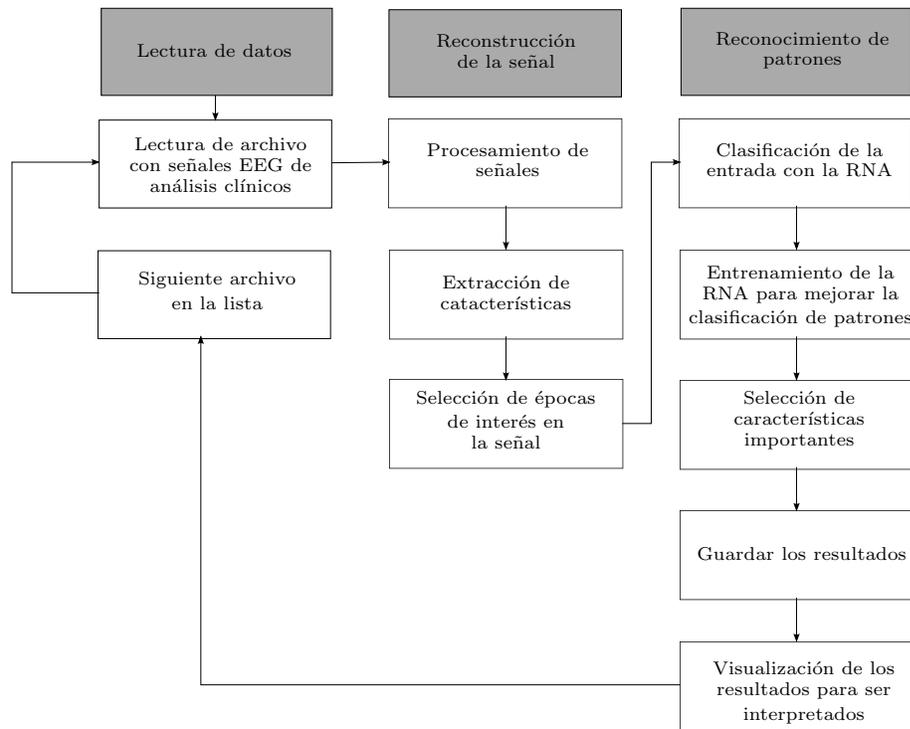


Figura 4.2 – El proceso realizado para comprender como se conforman las entradas de la RNA.

La forma más común de analizar el comportamiento espectral de una señal con respecto al tiempo es el análisis de tiempo-frecuencia [16]. Existen varios métodos que en la actualidad son usados para realizar este análisis [1, 5, 10, 14, 15]. Para esta investigación se utilizó la DW y FT porque permiten obtener los componentes de frecuencia de una señal. Dichos componentes son utilizados para analizar la evolución de una señal con respecto al tiempo, es decir, su amplitud y frecuencia que son requeridos para verificar el comportamiento de algún patrón.

El resultado de los procesos de separación y análisis de frecuencia es guardado en múltiples archivos, separando así cada uno de los canales del EEG. Cada uno de estos archivos contienen las entradas que la RNA utilizará para el método de aprendizaje.

4.1.3 MODELO LVQ

LVQ es un modelo de aprendizaje que tiene como fin el representar los datos de entrenamiento en clases predefinidas mediante el uso de vectores representativos [9]. El objetivo principal de este modelo es representar los datos con el menor número de clases y a su vez perder la menor información relevante posible. Posteriormente es posible realizar una clasificación de los resultados obtenidos a partir de las clases identificadas.

Para poder realizar una clasificación correcta es necesario tener un patrón identificado que sirva para alimentar la RNA. Con esta clasificación los nuevos datos de entrada (que actualmente son desconocidos) que posiblemente presenten algún tipo de patrón fácilmente se podrán asignar a una de estas clases para ser identificados.

En la figura 4.3 se muestra la arquitectura que compone el modelo LVQ.

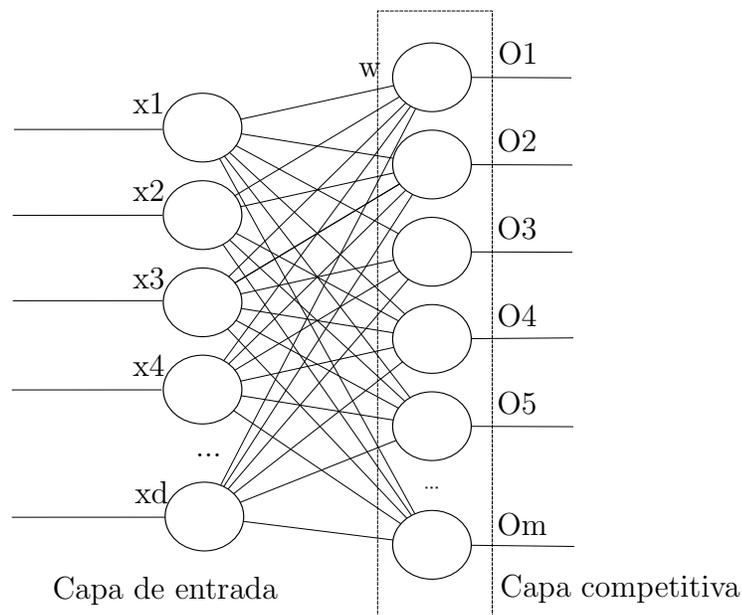


Figura 4.3 – La Arquitectura LVQ está compuesta por dos capas principales. La capa competitiva realiza una clasificación por cada una de las clases.

LVQ permite la clasificación de un número de entradas que representan alguna característica en específico en un conjunto de clases representativas. Por lo tanto,

cada elemento de la entrada debe ser asignado a una clase que lo represente con la mayor precisión posible.

Cabe destacar que para realizar una representación correcta se tiene que saber en un principio cuántas clases pueden existir y cuál clase pertenece a la entrada de entrenamiento. Si dos entradas son similares, se clasifican en la misma clase, por lo cual no existe algún mecanismo diseñado para detectar este tipo de diferencias entre dos entradas similares. El modelo LVQ aprende a clasificar entradas que se hayan especificado con anterioridad, por lo cual el entrenamiento supervisado puede reducir errores de clasificación que presenten alguna proximidad de distancias entre las entradas.

Los experimentos realizados ponen en evidencia que el modelo LVQ se adapta fácilmente a los distintos experimentos realizados y que los resultados obtenidos son comparables, y en algunos casos superan a los métodos tradicionales utilizados.

4.2 IMPLEMENTACIÓN

La implementación de la solución consiste en describir el trabajo realizado de manera detallada para poder comprobar la hipótesis propuesta durante todas las etapas identificadas en la metodología.

Se describen brevemente los componentes de software usados para poder realizar la aplicación y obtener los resultados. En segunda instancia se describe la arquitectura usada para la RNA, la cual consiste en explicar el modelo usado para poder realizar el reconocimiento de patrones epilépticos, después se discute la inicialización de la RNA con los datos de entrenamiento, la cual consiste en describir la técnica usada para iniciar este proceso de clasificación; después se aborda la regla de aprendizaje, la cual consiste en describir el proceso usado por la RNA para aprender de los datos

de entrenamiento. El entrenamiento, que consiste en describir el proceso en si que la RNA usa para descubrir estas clases específicas identificadas como puntos de interés para clasificar SW.

4.2.1 COMPONENTES DE SOFTWARE

Una parte fundamental a la hora de desarrollar un proyecto de software es hacer una selección de las herramientas que existen actualmente. Una de las razones principales por la cual se ha tomado en cuenta usar el lenguaje de programación PYTHON es porque es un lenguaje que permite realizar programas que requieren de mucha memoria de forma muy simple, lo cual es una ventaja para este proyecto debido a que se maneja una gran cantidad de información de datos. Otra ventaja que cabe destacar es su fácil y ordenada sintaxis que permite lograr prototipos funcionales en poco tiempo.

La intención de este proyecto siempre fue realizar una programa de software que no necesitara de muchas librerías tales como MNE Python⁵, PyEEG⁶, etc. Sin embargo, sería un grave error no tomar en cuenta los aspectos que estas librerías construidas por muchos programadores con una mayor experiencia han aportado al campo de la extracción y interpretación del EEG, es por eso que se toman en cuenta como una referencia adicional para este proyecto. No obstante si se debe de mencionar que se implementan librerías básicas que permiten manipular y analizar las señales del EEG y que Python incluye por defecto, esto debido a que los datos exportados del EEG están en formato de texto plano (datos cuantitativos por así decirlo) y que esto nos permitirá desarrollar un archivo de entrada con un estándar establecido en primera instancia y que el programa requiera de una instalación mas simple.

⁵MNE Python fue diseñado realiza análisis de tiempo-frecuencia de EEG.

⁶PyEEG es un módulo de Python que contiene funciones para construir datos para la extracción de características EEG, tales como la construcción de una secuencia de la incorporación de una serie de tiempo dado.

4.2.2 ARQUITECTURA RNA

La arquitectura LVQ trata de establecer una correspondencia entre la información de entrada y un espacio de salida de dos dimensiones, o mapa topológico [4]. Esta arquitectura diseñada para la RNA consiste principalmente en el uso de dos capas. La primera capa es una capa competitiva. La segunda capa transforma las clases de la primera capa competitiva y produce una clasificación definida por el usuario, dependiendo de la cantidad de entradas del EEG utilizadas para el entrenamiento. Ambas capas competitivas tienen una neurona por cada una de las clases definidas para entrenamiento; las clases corresponden a la cantidad de señales del EEG usadas como entrada. Esta arquitectura se puede observar en la figura 4.4, en donde R es el número de entradas, S_1 es el número de neuronas competitivas, S_2 es el número de neuronas dentro de la capa lineal, W_1 es el vector de pesos de las neuronas competitivas, y W_2 es el vector de pesos de las neuronas de la capa lineal y a_i es la tasa de aprendizaje correspondiente a cada una de las capas.

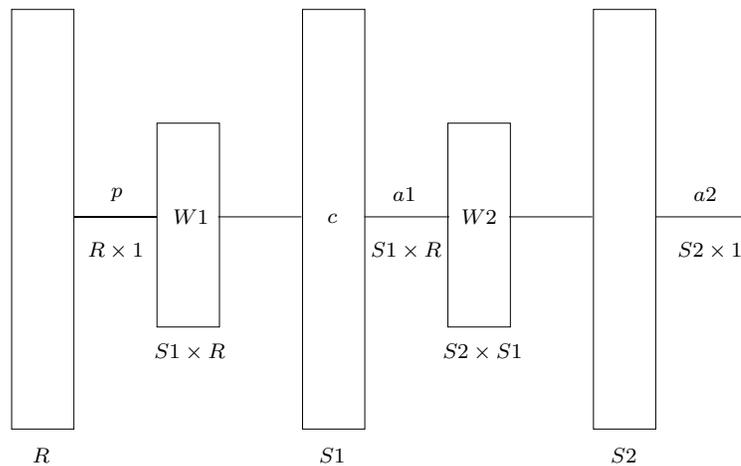


Figura 4.4 – Arquitectura usada para realizar el reconocimiento de patrones epilépticos.

4.2.3 INICIALIZACIÓN

Dado el vector de entrada p representando una época por cada uno de los electrodos medidos, el número de neuronas s , y los vectores de aproximación t , los pesos W_l son inicializados con valor de cero. Cada peso W_i es asociado con una entrada p_i y es puesto en marcha para su procesamiento. Los índices para las clases del vector de entrenamiento son convertidos en vectores de aproximación t . Cada índice dentro del vector es convertido a una matriz de forma $M \times N$ en donde N es el número de índices y M es el índice mayor del tipo de clase. En adición a lo mencionado, los vectores de aproximación son elementos entre cero y uno. Esto para destacar cuales son los electrodos usados para realizar un entrenamiento y cuales se deben de mantener apagados. Es sumamente importante aclarar que el entrenamiento que se haga debe de definir estos vectores para la correcta inicialización de los pesos de la segunda capa. Cabe destacar que el número de neuronas utilizadas para detectar un patrón epiléptico depende directamente del número de entradas correspondientes a ese patrón.

4.2.4 REGLA DE APRENDIZAJE

Una vez que la RNA haya inicializado, las neuronas en la capa competitiva son asignadas a la capa lineal y así el entrenamiento puede empezar. La regla de aprendizaje utilizada para LVQ fue desarrollada con la regla de Kohonen [13]. Cuando se aplica esta regla, la neurona competitiva que tiene el vector de pesos más parecido al vector de entrada gana la competencia y devuelve una salida con valor a uno. Solamente los pesos de la neurona ganadora son actualizados para así moverse más cerca al vector de la entrada. La regla de Kohonen es definida de la siguiente manera

$$\Delta W_{1(i,j)} = r_1 a_{1(i)} [p_{(j)} - W_{1(i,j)}], \quad (4.1)$$

en donde $\Delta W_{1(i,j)}$ es el peso actualizado de la neurona i ganadora en la capa competitiva, r_1 es la tasa de aprendizaje, y p es el vector de entrada. En las RNA que utilizan LVQ el vector de entrada t_1 para la capa competitiva es encontrada usando los pesos W_2 de la capa lineal, los cuales son asignados desde las neuronas competitivas hasta las neuronas de entrada hacia los vectores de aproximación de la RNA de la siguiente manera

$$t_1 = W_2^T t, \quad (4.2)$$

en donde T se refiere a la matriz transpuesta⁷ del conjunto de los pesos W_2 . Esta expresión transforma un vector de aproximación t para una capa de entrada, conteniendo un valor entre cero y uno en las posiciones de todas las neuronas las cuales son sub-clases del vector de aproximación.

La regla de Kohonen es usada, como se menciona anteriormente, para actualizar los pesos de las neuronas en la capa competitiva i cuando el vector de aproximación para la neurona es uno [13]. De esta manera, únicamente los pesos de las neuronas ganadoras se mueven conforme al vector de entrada si son sub-clases del mismo. Todas las demás neuronas que no hayan ganado no se mueven hacia ninguna dirección.

4.2.5 ENTRENAMIENTO

La RNA de LVQ es entrenada aplicando de manera repetitiva la regla de aprendizaje de Kohonen en la entrada y el vector de entrada en un orden secuencial. Los pesos W_1 y W_2 , la entrada p y los vectores de entrada t son usados en el entrenamiento para modificar los pesos de las neuronas. Los ciclos de entrenamiento son repetidos con una tasa de aprendizaje de 0,05 hasta que las neuronas competitivas se acercan a su clase asignada de su vector de entrada, periódicamente la tasa de

⁷Dada una matriz A , se llama matriz traspuesta de A a la matriz que se obtiene cambiando ordenadamente las filas por las columnas.

aprendizaje es reducida para realizar una aproximación más precisa. El entrenamiento es finalizado cuando se han leído por completo los archivos de entrenamiento, esto conlleva a verificar que tan cerca están las neuronas competitivas a su clase asignada del vector de entrada.

CAPÍTULO 5

EVALUACIÓN

Para un completo desarrollo de software es necesario realizar sus pruebas correspondientes, con las cuales es posible detectar errores, defectos o vulnerabilidades que se pueden reparar para ofrecer un mejor funcionamiento. En este caso se realizan dos tipos de pruebas. Las pruebas de clasificación, que consisten en verificar el estado de aceptación a la detección de patrones epilépticos después de haber realizado un entrenamiento con la RNA y las pruebas de rendimiento, que consisten en cuantificar los tiempos de ejecución del programa y otros parámetros que son necesarios para realizar modelos estadísticos precisos.

Cabe destacar que al permitir que el proyecto pueda realizar un entrenamiento con un mayor número de entradas disponibles se busca acumular más evidencia que permita realizar futuras revisiones y poder avalar mejor los resultados obtenidos. A continuación se presenta el análisis de los resultados obtenidos en los experimentos diseñados.

5.1 DISEÑO EXPERIMENTAL

Según Montgomery [12] un experimento es una prueba o serie de pruebas en las que se hacen cambios deliberados en las variables de entrada de un proceso o sistema para observar e identificar las razones de los cambios que pudieran observarse en la

respuesta de salida.

La evaluación de las pruebas diagnósticas se ha tratado, en general, sin un criterio universalmente aceptado. En diferentes estudios aparecen términos como sensibilidad, especificidad, eficiencia, exactitud, utilidad, valor, eficacia y efectividad, pero a menudo el significado es interpretado de diferentes maneras. Debido a estas interpretaciones, tanto en el concepto, como en la medida de la calidad de un experimento diagnóstico, se crea una situación de confusión a la hora de resolver cuestiones concretas [2]. Es por eso que para el funcionamiento adecuado del software se realizaron varios experimentos que ayudarán a verificar la calidad de clasificación epiléptica del tipo SW.

Para evaluar el rendimiento del software bajo estas circunstancias, se toman en cuenta los siguientes evaluaciones:

Discriminación. Se analiza la relación entre los resultados positivos y negativos obtenidos de las pruebas de los análisis clínicos. Se utilizan herramientas estadísticas en los resultados obtenidos para verificar que el sistema efectivamente pueda distinguir algún tipo de patrón entre los resultados y con que porcentaje efectivamente acierta.

Calibración. Se analiza el grado de correspondencia entre las probabilidades estimadas de mortalidad producidas por el modelo propuesto y la mortalidad real.

Desempeño. Se analiza cuál es la mejor RNA en términos de tolerancia de entrenamiento, la arquitectura usada y algoritmo de aprendizaje; con la intención de validar que efectivamente se ha utilizado una RNA que permita una buena clasificación.

Procesamiento. Se evalúa el tiempo estimado que el software necesita para realizar

las operaciones necesarias para clasificar una entrada. Dependiendo de la plataforma y el *hardware* en que se ejecuta el software podrían existir diferencias de velocidad.

Para poder determinar que entradas son de mayor influencia para el proceso de entrenamiento de la RNA se deben de hacer los experimentos correspondientes que determinen dichas entradas para producir una salida deseada. El propósito de esta investigación es determinar si existe un patrón epiléptico del tipo SW dentro de los datos experimentales usando RNA con el fin de ayudar al equipo de especialistas médicos a diagnosticar con mayor precisión esta enfermedad.

Estas pruebas se realizan mediante rutinas que ejecutan métodos específicos del software o ejecución completa, siempre con diferentes parámetros. Se llevan a cabo en plataformas distintas bajo circunstancias de *hardware* variadas (ejecución única, ejecución junto a otros programas, etcétera).

5.1.1 DISCRIMINACIÓN

La discriminación es la capacidad de distinguir entre dos estados, es por eso que para valorarla se emplean tablas de contingencia¹ eligiendo un valor límite, estableciendo porcentajes de correcta clasificación y analizando las curvas ROC resultantes especialmente calculando el área bajo la curva.

Con frecuencia los resultados de las pruebas diagnósticas están distribuidos en una escala continua², por lo que es necesario seleccionar un valor límite adecuado que permita resumir estos resultados en dos categorías: positivo y negativo. Dependiendo de la evaluación preliminar que el médico especialista proporcione, los resultados

¹Las tablas de contingencia se emplean para registrar y analizar la relación entre dos o más variables.

²Una escala continua consta con medidores con categorías o números donde el evaluador simplemente marca su estimación.

pueden ser o no ser efectivamente acertados a lo que un diagnóstico médico correcto puede ser.

5.1.2 CALIBRACIÓN

La calibración es la exactitud del modelo comparando la probabilidad esperada y la observada, es por eso que para evaluarla se utilizan las pruebas estadísticas de ajuste de bondad de Hosmer-Lemeshow. Esta prueba comprobará si el modelo propuesto puede explicar lo que se observa. Evaluando la distancia entre lo observado en los datos obtenidos y lo esperado bajo el modelo actual se puede evaluar el resultado obtenido simplemente en dos estados, cero y uno. Cabe destacar que se requiere un número de observaciones amplio para realizar este experimento.

Para realizar esta evaluación estadística se necesita tomar en cuenta información de los pacientes con problemas epilépticos del tipo SW. Se debe de calcular el porcentaje de riesgo o índice de mortalidad utilizando el modelo logístico y luego se debe de hacer una clasificación según esta probabilidad de riesgo.

5.1.3 DESEMPEÑO

El procedimiento para evaluar el desempeño consistió en realizar los tres reportes con respecto a la cantidad de archivos de entradas que la RNA con diferentes arquitecturas procesadas y clasificadas. A partir de esto se pudo medir el desempeño usando el modelo propuesto y compararlo con otros modelos usados frecuentemente.

En computación neuronal las medidas de desempeño son usadas para seleccionar el mejor modelo en términos de arquitectura, algoritmo de entrenamiento, parámetros de entrenamiento, etc. Según los antecedentes que se han podido investigar, tres reportes se han usado comúnmente para evaluar las medidas de desempeño de una

RNA:

Error cuadrático medio (ECM). Es definido como

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2, \quad (5.1)$$

donde \hat{Y}_i es la salida deseada observada en el tiempo i , Y_i es la salida obtenida y n es el total de la muestra actual.

Porcentaje de buena clasificación (PBC). El PBC es definido como:

$$PBC = \frac{C}{(R_{fa} + 0,2) + (T_{dly} * P_{dct} + P_{msd})}, \quad (5.2)$$

donde C es una constante de escala, normalmente es 10 para poder leerla fácilmente. (R_{fa} es el número de falsas alarmas detectadas, T_{dly} es la media del retraso ocurrido cuando se clasificó en segundos; es una medida que representa la sumatoria del número total de clasificaciones correctas sobre todos los patrones usados como entrada.

Típicamente la mayoría de los investigadores consultados solo utilizan una medida de desempeño para indicar la buena calidad de desempeño de su RNA. Sin embargo, no hay una aprobación en cuanto a que la medida debe ser reportado de esa forma, y por lo tanto, las comparaciones entre las técnicas y resultados de diferentes investigadores a veces son prácticamente imposibles.

5.2 RESULTADOS

Después de realizar el diseño experimental, se evaluaron los resultados obtenidos. En esta sección se realiza un enfoque en el porcentaje de correcta clasificación que se

obtuvo a partir de los experimentos y en el desempeño de la aplicación. Se generaron *scripts*³ que corren solo ciertas partes del programa y guardan información obtenida utilizada para poder evaluarlos.

5.2.1 DISCRIMINACIÓN

El experimento está definido en la sección 5.1.1 y consistió principalmente en establecer un valor límite mínimo y máximo por cada uno de los electrodos usados dentro de cada uno de los archivos de entrenamiento que permitiera observar el porcentaje de aceptación entre valores y probar que la clasificación realizada con la RNA del tipo LVQ puede contabilizar los casos de éxito, fracaso y error.

Para poder definir los valores mínimo y máximo se realizó un promedio de las entradas usadas como salida deseada por cada uno de los electrodos evaluados durante el proceso de clasificación. Cabe destacar que cada uno de los conjuntos de datos de entrada analizados tienen sus propios límites de discriminación. Se demuestran dichos límites en la figura 5.1 usados en diferentes periodos de entrenamientos.

Después se evaluó en promedio cuales eran las salidas de las neuronas que no pertenecían a los valores límites y con esto se calculó el porcentaje de discriminación, indicando la tolerancia con la cuál la RNA aproxima las salidas de las neuronas de las diversas capas a la salida deseada, es decir, que tan aproximada puede llegar a ser una clasificación analizada.

³Un *script* es un conjunto de instrucciones interpretadas por el sistema operativo para realizar tareas simples.

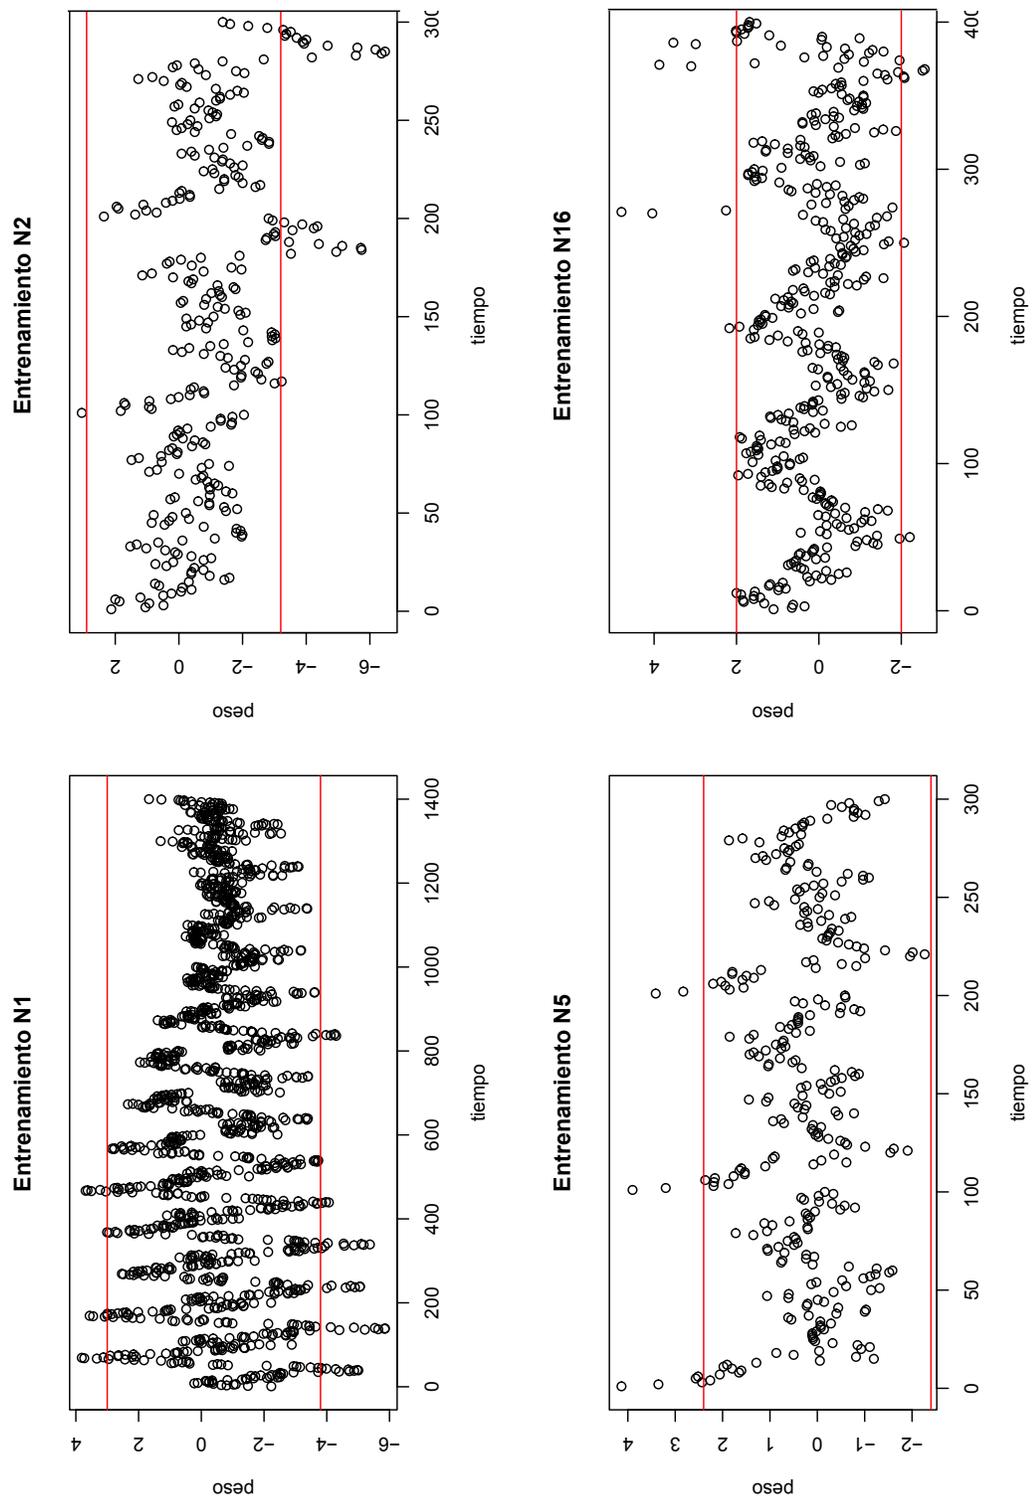


Figura 5.1 – Se demuestran los límites mínimo y máximo que pueden tener cada clasificación de cada una de las neuronas en la RNA.

Cuadro 5.1 – Análisis de la discriminación, porcentaje del resultado evaluando los límites establecidos como aceptables.

Conjunto de datos	Discriminación
TMSP0000	48.7 %
TMSP0001	49.7 %
TMSP0002	51.1 %
TMSP0003	63.1 %
TMSP0006	61.6 %
TMSP0007	58.2 %

En el cuadro 5.1 se muestra el porcentaje obtenido de discriminación por cada uno de los conjuntos de datos establecidos como entradas experimentales.

Como se puede observar, el porcentaje promedio de discriminación se mantiene por encima del cincuenta por ciento lo cuál indica una ventana abierta a algunos valores que no son directamente usados para realizar una buena clasificación, sin embargo, esto puede llegar a corregirse cuando un médico especialista realiza una separación de los datos de entrenamiento con datos de ruido.

5.2.2 CALIBRACIÓN

El experimento está definido en la sección 5.1.2 y consistió en analizar el grado de correspondencia entre el resultado obtenido y el esperado. El objetivo de la prueba es evaluar qué tan efectivo fue la clasificación de los patrones epilépticos con el entrenamiento y qué tan preciso se ajustó en la RNA. En el cuadro 5.2 se muestran los resultados del experimento.

Mediante los datos de entrenamiento clasificados por los médicos especialistas se pudo identificar a los pacientes que presentaban el SW y en qué épocas del análisis clínico se podían evaluar, por lo cual se formó un grupo de control de valores esperados y se pudo observar contra el resultado que la RNA proporcionó al clasificar estos patrones. Entre más fiel sea el porcentaje de riesgo calculado mayor será su porcentaje de

Cuadro 5.2 – Análisis de la calibración, porcentaje obtenido evaluando los criterios definidos por el medico especialista.

Conjunto de datos	Calibración
TMSP0000	80.23 %
TMSP0001	96.16 %
TMSP0002	96.10 %
TMSP0003	92.13 %
TMSP0006	81.76 %
TMSP0007	88.34 %

calibración correcta.

El porcentaje de calibración mostrado proporcionan resultados variables. Cuando este porcentaje es muy bajo se puede decir que no se obtuvo una clasificación aproximada a lo observado, lo cual demuestra que existe un factor de riesgo cuando se definen datos de entrenamiento con pocos patrones encontrados; un mayor número de registros con diferentes tipos de amplitudes es requerido para una mejor calibración.

El método de aprendizaje LVQ tiende a realizar clasificaciones de los diversos patrones y tiende a requerir resultados esperados ya calculados con anterioridad, sin embargo, los resultados demuestran un nivel de calibración aceptable.

5.2.3 DESEMPEÑO

El experimento está definido en la sección 5.1.3 y consistió en analizar la cantidad de faltas que se pasan por alto entre los resultados de los pacientes con condiciones particulares al caso SW y los de aquellos que no las tienen; es por eso que en el caso de la prueba de desempeño se modifican aspectos internos del programa para obtener una correcta clasificación del patrón epiléptico SW; un umbral o valor límite que se establece como un porcentaje de correcta clasificación. Los casos utilizados son los siguientes:

Verdaderos positivos (VP). La RNA identificó un patrón que fue catalogado correctamente y verificado por el médico especialista.

Verdaderos negativos (VN). Tanto como la RNA y el médico especialista acordaron que el patrón es normal.

Falsos positivos (FP) La RNA identificó un patrón que fue catalogado como normal por el médico especialista.

Falsos negativos (FN). La RNA ha fallado al identificar un patrón que el médico especialista ha catalogado como correcto.

Cuadro 5.3 – Análisis de desempeño, se compara la precisión en porcentaje con la que la RNA acierta en clasificación.

Conjunto de datos	VP	VN	FP	FN
TMSP0000	67.72 %	16.68 %	14.69 %	0.89 %
TMSP0001	91.62 %	3.65 %	3.62 %	1.09 %
TMSP0002	92.04 %	3.76 %	3.70 %	0.51 %
TMSP0003	84.62 %	7.22 %	6.79 %	1.36 %
TMSP0006	78.99 %	10.44 %	9.19 %	1.36 %

En la prueba de desempeño se modifican parámetros de entrenamiento de la RNA, como la tasa de aprendizaje que es utilizado para ajustar los pesos de cada neurona dentro de las diversas capas usadas para la clasificación.

Las ecuaciones utilizadas para el cálculo se expresan como:

Sensibilidad:

$$\left(\frac{VP}{VP + FN} \right) \times 100 \quad (5.3)$$

Especificidad:

$$\left(\frac{VN}{VN + FP} \right) \times 100 \quad (5.4)$$

Selectividad:

$$\left(\frac{VP}{VP + FP} \right) \times 100 \quad (5.5)$$

Precisión:

$$\frac{Sensibilidad + Especificidad}{2} \quad (5.6)$$

Cuadro 5.4 – Resultados utilizando las ecuaciones de precisión.

Conjunto	Sensibilidad	Especificidad	Selectividad	Precisión
TMSP0000	98.7 %	53.1 %	82.1 %	75.9 %
TMSP0001	98.8 %	50.2 %	96.1 %	74.5 %
TMSP0002	99.4 %	50.4 %	96.1 %	74.9 %
TMSP0003	98.4 %	51.5 %	92.5 %	74.9 %
TMSP0006	98.3 %	53.1 %	89.5 %	75.7 %

Los resultados del experimento se basan en validar la salida deseada de las neuronas en los archivos de entrenamiento y capturarla manualmente de forma secuencial por cada entrada procesada. El experimento indica un buen desempeño en la clasificación catalogando la información en mayor parte como VP, lo cual sugiere que el entrenamiento supervisado ha establecido límites congruentes de un patrón establecido, sin embargo la precisión se ve afectada debido al cálculo de especificidad, que refiere a la cantidad de errores observados por el médico especialista por lo cual se asume un porcentaje de riesgo al realizar un diagnóstico médico.

5.2.4 RENDIMIENTO

En total se realizaron tres pruebas de rendimiento. Cada prueba se realiza en las plataformas LINUX⁴, WINDOWS⁵ y OS X⁶. En cada plataforma se realiza

⁴LINUX es un sistema operativo de libre distribución basado en UNIX (otro sistema operativo de libre distribución), desarrollado originalmente por Linus Torvalds.

⁵MICROSOFT WINDOWS es el nombre de una familia de sistemas operativos desarrollados y vendidos por MICROSOFT.

⁶OS X, antes llamado MAC OS X, es una serie de sistemas operativos basados en UNIX desarrollados, comercializados y vendidos por APPLE INC. que ha sido incluido en su gama de computadoras MACINTOSH desde el año de 2002.

la prueba sin procesos en ejecución (correr el programa con la mayor cantidad de memoria disponible) y con varios procesos en ejecución (correr el programa solo con memoria suficiente). La cantidad de repeticiones depende del conjunto de archivos de entrenamiento utilizados, rondando entre las 160,000 y 350,000 iteraciones por 22 señales eléctricas procesadas, lo cuál nos da un total aproximado de 7,700,700 iteraciones por análisis clínico.

La prueba de velocidad de procesamiento se realizó tomando los tiempos que tarda el programa para generar los datos, procesarlos, compararlos y dar una respuesta; en este caso la respuesta es la clasificación correcta o incorrecta de la entrada procesada por la RNA.

Cuadro 5.5 – Comparativa de velocidad de procesamiento usando distintos parámetros tanto de *hardware* como de *software*.

Sistema operativo	Tiempo de procesamiento	Tiempo de ejecución
Mac OS X	70m 46s	70m 8s
Ubuntu	46m 29s	46m 19s
Windows	64m 22s	64m 3s

Los resultados de esta prueba indican que el entrenamiento realizado es lento, toma un tiempo total aproximado de la clasificación de todas las señales eléctricas, entre 45 y 70 minutos.

El programa realiza todas estas operaciones en un promedio de 60 minutos por análisis clínico. El experimento demuestra que mientras mas señales eléctricas sean procesadas es mayor el tiempo de ejecución, sin embargo, es factible el poder realizar diferentes entrenamientos de la RNA con una menor cantidad de información analizada debido a que los canales por los cuales se graba la información eléctrica del cerebro puede variar o permanecer prácticamente nula, lo cual la vuelve irrelevante. Es necesario involucrar al médico especialista en la actividad de identificación y preprocesamiento de los archivos de entrada para señalar los canales en los que se concentrará el estudio

Cuadro 5.6 – Se comparan los resultados obtenidos y se analizan los recursos utilizados en cada sistema operativo.

Sistema operativo	Recursos utilizados con preprocesamiento	Recursos utilizados sin preprocesamiento
Mac OS X	11.83 MB	11.81 MB
Ubuntu	9.41 MB	9.40 MB
Windows	11.02 MB	10.91 MB

realizado.

En el cuadro 5.6 se puede observar la cantidad de memoria utilizada en *megabytes* (MB) para la ejecución del programa por cada entrenamiento utilizando como criterio principal de evaluación el preprocesamiento de señales. El experimento demuestra que los recursos consumidos por el sistema operativo se ven ligeramente aumentados por el preprocesamiento de señales, esto debido a que aumenta la cantidad de datos de entrada y toma parte de los recursos para ejecutarse. El procesamiento de un archivo de entrada alarga aproximadamente un 72% el tiempo de ejecución y el consumo de recursos del programa, debido a que realiza un proceso iterativo por cada una de las entradas producidas.

Se puede concluir que el programa realiza sus funciones en menos tiempo cuando realizamos una clasificación fragmentando los archivos de entrada. Es factible el dividir la cantidad de filas por archivo de datos de entrenamiento para poder realizar un proceso continuo de entrenamiento, disminuyendo así las iteraciones realizadas.

CAPÍTULO 6

CONCLUSIONES

Durante el desarrollo de este proyecto se presentó un software con la capacidad de procesar información, clasificar, pronosticar y detectar patrones epilépticos que tengan ciertas características. La finalidad de este programa es ayudar a mejorar la eficacia de un diagnóstico médico acertado.

Se implementaron métodos de análisis de señales y detección de patrones, los cuales permitieron detectar en las señales EEG patrones epilépticos del tipo SW por medio de una clasificación y un entrenamiento, tomando en cuenta algunas características de estos patrones identificadas por los médicos especialistas.

Para producir una mejor clasificación y entrenamiento se tomaron en cuenta diferentes métodos de procesamiento evaluando de manera diferente la cantidad de entradas que la RNA usó para identificar los patrones epilépticos. Cabe destacar que en la fase de experimentación se realizaron diferentes tipos de arquitecturas con diferentes capas de entrada, ocultas y de salida.

El desarrollo principal se realizó en el lenguaje de programación PYTHON mientras que algunas rutinas de procesamiento se codificaron en el lenguaje de programación R debido a la carga algorítmica y la diversidad de librerías de medición que esta contiene.

6.1 DISCUSIÓN

El prototipo de *software* desarrollado demuestra que sus resultados son favorables en cuanto a su objetivo principal, de acuerdo a las pruebas realizadas. Existe una cierta aproximación cuantitativa a lo que una detección epiléptica del tipo SW puede presentarse en un análisis clínico.

Los resultados obtenidos de las evaluaciones de discriminación y calibración, demuestran un porcentaje de aceptación suficiente en lo que respecta a la clasificación de las señales. Esto puede indicar que existe un área de oportunidad al realizar un mayor número de experimentos supervisados para poder reevaluar los resultados presentados y ampliar la experimentación de esta investigación.

Aunque los resultados de ejecución del *software* son los esperados, existen problemas de velocidad de procesamiento, esto es debido a la cantidad de entradas que el *software* necesita procesar. Una alternativa viable es segmentar los procesos ejecutados y en algún período ir juntando los resultados de acuerdo a los parámetros establecidos en el entrenamiento de la RNA.

El *software* necesita una gran cantidad de recursos para ejecutarse. Además existe una probabilidad de que las entradas presenten errores de medición, lo que genera una pequeña pérdida de datos que podría a su vez producir cambios en los resultados. La lectura de los archivos de entrada requiere aproximadamente 70 % del tiempo de ejecución total, por lo cual se experimenta un consumo mayor al esperado, lo que representa otra área de oportunidad para esta investigación el poder reducir este consumo.

6.2 TRABAJO A FUTURO

El estudio presentado resultó ser bastante complejo debido a los múltiples campos de estudios combinados, como lo es la ingeniería de *software* y la medicina; es por esto que existe mucho trabajo por realizar para lograr tener un producto completamente funcional y que tenga las condiciones de usarlo en diagnósticos clínicos reales.

Lamentablemente durante el proceso de investigación de esta tesis el departamento de neurofisiología perdió una gran cantidad de información relevante al caso SW de sus bases de datos debido a un problema técnico con su equipo de diagnóstico médico. Como anteriormente se ha mencionado, el estudio de la detección de patrones en señales eléctricas requiere de una gran cantidad de datos de entrada por lo cual se pretende seguir colaborando con este departamento para poder adquirir más análisis clínicos y poder expandir esta investigación en un futuro cercano.

Los cambios inmediatos en el *software* podrían ser mejoras a los algoritmos y a las rutinas en general. Además, se podrían agregar nuevas funciones de acuerdo a las tendencias actuales que hagan más atractiva la idea de este *software* y agregar opciones de personalización. Finalmente se podría trabajar en una interfaz gráfica que permita una mejor visualización de los resultados obtenidos.

BIBLIOGRAFÍA

- [1] C.F. Boos, G.R. Scolaro, M.C.V. Pereira y F.M. Azevedo. Analysis of pre-processing methods for artificial neural networks pattern recognition of EEG signals. *World Congress on Medical Physics and Biomedical Engineering*, págs 558–561, 2013.
- [2] M.J. Burgueno, J.L. García Bastos y J.M. González Buitrago. Las curvas roc en la evaluación de las pruebas diagnósticas. *Servicio de Análisis Clínicos. Hospital General Yague. Universidad de Salamanca*, págs 661–670, 1997.
- [3] Amitava Chatterjee, Amine Nait-Ali y Patrick Siarry. Neural network approaches for EEG classification. *Springer-Verlag Berlin Heidelberg*, págs 165–182, 2009.
- [4] Félix de Moya Anegón, Victor Herrero Solana y Vicente Guerrero Bote. La aplicación de redes neuronales artificiales: a la recuperación de la información. *Revistes Catalanes amb Accés Obert*, págs 147–164, 1998.
- [5] Xiao-Zhi Gao, Jing Wang, Jarno M. A. Tanskanen, Rongfang Bie, Xiaolei Wang, Ping Guo y Kai Zenger. Optimal classification of epileptic EEG signals using neural networks and harmony search methods. *Journal of Software*, 9:230–239, 2014.
- [6] R. Harikumar, C. Ganeshbabu, M. Balasubramani y P. Sinthiya. *Analysis of*

- SVD Neural Networks for Classification of Epilepsy Risk Level from EEG Signals*, volumen 2. Springer Science and Business Media, 2013.
- [7] Wael Hayel Khreisat. Clinical profile of infants with hypsarrhythmia. *Acta Informatica Medica*, 19:149–152, 2011.
- [8] T. Kohonen, G. Barna y R. Chrisley. Statistical pattern recognition with neural networks: benchmarking studies. *Neural Networks, 1988., IEEE International Conference on*, 1(61-68), 1988.
- [9] David Kriesel. *A Brief Introduction to Neural Networks*. Consultado el 15 de agosto, 2005.
- [10] Sang-Hong Lee, Joon S. Lim, Jae-Kwon Kim, Junggi Yang y Youngho Lee. Classification of normal and epileptic seizure EEG signals using wavelet transform, phase-space reconstruction, and euclidean distance. *Computer methods and programs in biomedicine*, págs 10–25, 2014.
- [11] P. Marchena, M. Díaz, R. Esteller, I. Martínez y A. Zambrano. Use of artificial neural networks for classification intercraneal EEG signals from epileptic patients. *World Congress on Medical Physics and Biomedical Engineering*, págs 398–401, 2009.
- [12] Douglas Montgomery. *Design and Analysis of Experiments*. SAS Institute Inc., 2013.
- [13] N. Pradhan, P.K. Sadasivan y G.R Arunodaya. Detection of seizure in eeg by an artificial neural network: A preliminary study. *Computers and Biomedical Research*, 29(0022):303–313, 1996.
- [14] Cenk Sahin, Seyfettin Noyan Ogulata, Kezban Aslan y Hacer Bozdemir. The application of neural networks in classification of epilepsy using EEG signals. *Advances in Brain, Vision, and Artificial Intelligence*, págs 499–508, 2007.

-
- [15] Abdulhamit Subasi y Ergun Erçelebi. Classification of EEG signals using neural network and logistic regression. *Computer methods and programs in biomedicine*, págs 87–99, 2005.
- [16] Laurent Uldry, Cédric Duchene, Yann Prudat, Micah M. Murray y Jean-Marc Vesin. Adaptive tracking of EEG frequency components. *Advanced Biosignal Processing*, págs 123–144, 2009.
- [17] Steven Walczak y William J. Nowack. An artificial neural network approach to diagnosing epilepsy using lateralized burst of theta eegs. *Journal of Medical Systems*, 25(1):9–20, 2001.
- [18] Mohd. Zuhair, Sonia Thomas, Anup Kumar Keshri, Rakesh Kumar Sinha, Kirat Pal y Dhruves Biswas. *Automatic Identification of an Epileptic Spike Pattern in an EEG Signals Using ANN*, págs 915–923. Springer India, 2014.

FICHA AUTOBIOGRÁFICA

David Sosa Valdes

Candidato para el grado de Ingeniero en Tecnología de Software

Universidad Autónoma de Nuevo León

Facultad de Ingeniería Mecánica y Eléctrica

Tesis:

SISTEMA DE RECONOCIMIENTO DE PATRONES
EPILÉPTICOS USANDO REDES NEURONALES
ARTIFICIALES

Nací el 17 de septiembre de 1989 en la ciudad de Monterrey, Nuevo León. Primer hijo de David Arturo Sosa Peralta y Dora Elia Valdes Lozano. Realicé mi bachillerato en la Preparatoria No. 15 Unidad Florida de la UANL durante el periodo 2007–2009. Inicié mis estudios universitarios en el agosto del 2009 en la Facultad de Ingeniería Mecánica y Eléctrica de la UANL en la carrera de Ingeniero en Tecnología de Software.