



Universidad Veracruzana

Instituto de Investigaciones en Inteligencia Artificial

Predicción de ataques epilépticos a partir de señales EEG
utilizando una red neuronal pulsante neuroevolucionada

Tesis para obtener el grado de:
Maestro en Inteligencia Artificial

Presenta:
Ing. Carlos Alberto López Herrera

Director: **Dr. Héctor Gabriel Acosta Mesa**
Co-Director: **Dr. Efrén Mezura Montes**

Octubre, 2022

Dedicatoria

A mis padres, Estela y Alfonso, cuyo apoyo incondicional siempre ha sido constante y duradero. Un ejemplo de perseverancia.

A mi hermano Erik, por el entendimiento, la complicidad, las platicas, las risas y la música. We've been to hell and back.

A mi hermana Regina, por el simple hecho de ser y existir. Mi razón de llegar, estar y seguir.

Chulz, que en el silencio encuentres la paz que siempre buscaste.

Agradecimientos

En primer lugar, quiero agradecer a mi asesor Dr. Héctor Gabriel Acosta Mesa, quien desde el primer momento que lo contacté con la curiosidad de iniciar la maestría, no tuvo más que palabras de aliento y motivación. Gracias por la paciencia, los consejos y los conocimientos que me compartió durante este tiempo.

También, quiero agradecer a mi asesor Dr. Efrén Mezura Montes. Su pasión e interés en el cómputo evolutivo ha sido contagioso. Gracias por los conocimientos, los consejos y recomendaciones durante todo este proceso.

Gracias a mis compañeros de generación en la IIIA. Si bien la pandemia nos impidió convivir más, siempre fue grato escucharlos, verlos y compartir nuestras experiencias.

Gracias al Consejo Nacional de Ciencia y Tecnología (CONACyT) por el apoyo brindado mediante una beca, lo que me permitió realizar mis estudios de posgrado en la Universidad Veracruzana.

Resumen

La epilepsia es reconocida como uno de los trastornos neurológicos más comunes en la actualidad, afectando mayoritariamente a países de medianos y bajos recursos. Dentro de su descripción, se encuentra el padecimiento frecuente de ataques epilépticos, los cuales son eventos de crisis donde existe una descarga eléctrica excesiva en un grupo de células cerebrales. Dado el gran impacto en salud y bienestar que estos ataques pueden tener en un paciente, la predicción de ellos es un tema de gran importancia.

Esta tarea resulta en un problema altamente dinámico y caótico, toda vez que la anticipación de un ataque epiléptico suele ser por medio de señales electroencefalográficas. Algunos métodos de inteligencia artificial han sido propuestos para facilitar este proceso. Sin embargo, la mayoría de ellos no aprovecha completamente la naturaleza temporal de las señales y de la problemática.

Así, este proyecto busca utilizar redes neuronales pulsantes como modelo de predicción de ataques epilépticos mediante la clasificación de características específicas de dichos eventos. La propuesta engloba el uso de NEAT como método de neuroevolución, abarcando la estructura y modificación de pesos de las redes generadas.

Como función de aptitud, se exploran dos aproximaciones. En la primera, se prioriza la capacidad de detectar casos realmente positivos (sensibilidad) y, en la segunda, se tiene como objetivo principal maximizar el tiempo de anticipación para una detección. Asimismo, se busca tener evidencia estadística de estas dos funciones mediante la repetición de cada experimento.

Los resultados muestran competitividad con el estado del arte. Desde el primer experimento, se logró aumentar el tiempo de anticipación de la detección conservando los rangos de sensibilidad. Por otro lado, con el segundo experimento, se logró aumentar aún más la anticipación. Sin embargo, esto provocó una disminución en la sensibilidad. De la misma manera, en ambos casos se observaron redes neuronales pulsantes de menor complejidad.

Índice general

Abstract	IV
Índice de figuras	VII
Índice de tablas	VIII
Productos Generados	IX
1 Introducción	1
1.1 Propuesta	3
1.2 Justificación	3
1.3 Hipótesis	3
1.4 Objetivos	4
1.4.1 General	4
1.4.2 Particulares	4
1.5 Estructura del documento	4
2 Marco Teórico	6
2.1 Epilepsia	6
2.2 Electroencefalografía	7
2.3 Redes Neuronales Pulsantes	8
2.4 Modelos neuronales	11
2.5 Cómputo Evolutivo	13
2.6 Neuroevolución	15
2.6.1 Mutación	17
2.6.2 Cruza	18
2.6.3 Especiación	19
3 Marco Referencial	21

4 Metodología	26
4.1 Base de datos	26
4.2 Preprocesamiento	27
4.3 Partición	28
4.4 Experimentación	28
4.5 Resultados	29
5 Experimentos y resultados	31
5.1 Parámetros utilizados	31
5.2 Entorno de ejecución	32
5.3 Experimento 1: Enfoque en sensibilidad	32
5.3.1 Neuroevolución	32
5.3.2 Validación	37
5.4 Experimento 2: Enfoque en SPH	38
5.4.1 Neuroevolución	38
5.4.2 Validación	42
5.5 Comparación con la literatura revisada	43
6 Conclusiones y Trabajo futuro	45
Referencias	50

Índice de figuras

1.1	Etapas de una señal epiléptica cerebral	2
2.1	Ejemplo de señales EEG	7
2.2	Diagrama del estándar 10-20	8
2.3	Ejemplo de una red neuronal profunda	9
2.4	Ejemplo de una LSTM	10
2.5	Esquema de la interacción biológica entre neuronas	10
2.6	Estructura SNN general completamente conectada	11
2.7	Modelo neuronal LIF	12
2.8	Esquema general de un EA	16
2.9	Estructura genotípica y su representación fenotípica de NEAT .	17
2.10	Mutaciones estructurales de NEAT	18
2.11	Operador de cruce de NEAT	19
4.1	Metodología propuesta	30
5.1	Gráficas de aptitud para el experimento 1	34
5.2	Gráficas de especies para el experimento 1	35
5.3	Mejores redes SNN neuroevolucionadas para el experimento 1 .	36
5.4	Gráficas de aptitud para el experimento 2	39
5.5	Gráficas de especies para el experimento 2	40
5.6	Mejores redes SNN neuroevolucionadas para el experimento 2 .	41
5.7	Comportamiento de la sensibilidad y SPH.	44

Índice de tablas

3.1	Revisión de los modelos propuestos para la predicción de ataques epilépticos.	23
3.2	Revisión de métodos CE y NE existentes aplicados a SNN.	24
4.1	Correspondencia de canales con la señal respectiva.	27
5.1	Parámetros utilizado para ambos experimentos.	32
5.2	Resultado de las ejecuciones de neuroevolución del experimento 1.	33
5.3	Resultado de la validación para las ejecuciones del experimento 1.	37
5.4	Resultado de las ejecuciones de neuroevolución del experimento 2.	38
5.5	Resultado de la validación para las ejecuciones del experimento 2.	42
5.6	Comparación de los experimentos realizados con los revisados en la literatura.	43

Productos Generados

Como parte del desarrollo de la maestría, se buscó generar productos de divulgación e investigación fuertemente ligados a los temas pertinentes del proyecto de tesis realizado.

Se logró generar el artículo de investigación titulado “Spiking Neural Networks Codification using Bio-Inspired Computation” [1], en el cual se explora la optimización de parámetros para la codificación de señales analógicas a trenes de pulso utilizando el algoritmo Ben’s Spiker Algorithm. En el, se muestra una comparación de tres algoritmos evolutivos contra un método de búsqueda de cuadrícula.

Como resultado, se demostró que la Evolución Diferencial superó a los otros algoritmos evolutivos, manteniendo las mismas capacidades de transformación que la búsqueda por cuadrícula.

Dicha investigación fue aceptada para su publicación dentro del 3er Workshop sobre Nuevas Tendencias en Inteligencia Computacional y Aplicaciones (CIAPP, por sus siglas en inglés) 2021. Esto también permitió realizar una presentación al respecto durante el congreso de Congreso Internacional Mexicano de Inteligencia Artificial (MICAI, por sus siglas en inglés) 2021.

Por otro lado, se pudo participar en los eventos del 7º Seminario de Socialización y Aprendizaje Computacional 2022 organizado por el Instituto de Investigaciones en Inteligencia Artificial (IIIA) de la Universidad Veracruzana (UV), con una presentación sobre el funcionamiento, aplicaciones y limitaciones de las redes neuronales pulsantes.

1 Introducción

La epilepsia, también conocida como trastorno de convulsiones, es una enfermedad neurológica que afecta a un gran sector de la población. Su definición engloba el padecimiento de convulsiones recurrentes en los pacientes. Si bien existen diversas causas que pueden derivar en este padecimiento, dentro de las más comunes se tienen a los accidentes cerebrovasculares, lesiones, tumores o infecciones cerebrales, algunos trastornos genéticos, entre otros [2]. Los ataques epilépticos representan un deterioro constante en la salud de aquellas personas que sufren de este padecimiento. Asimismo, este desorden también afecta el estado mental de los pacientes, causando ansiedad, depresión y deterioro cognitivo. También, las personas con epilepsia experimentan estigmatización y rechazo social [3]. En consecuencia, la confianza y autoestima de los pacientes se ve afectada [2].

De ahí que la predicción de ataques epilépticos es un reto de gran relevancia. Sin embargo, es una tarea altamente dinámica [4] en donde el Horizonte de Predicción de una Convulsión (SPH, por sus siglas en inglés) es de gran trascendencia para mejorar la calidad de vida de los pacientes, previniendo accidentes, alertando al personal médico y facilitando una intervención temprana [5], [6]. Esto, en gran medida, se puede lograr mediante la identificación de características evidentes en señales electroencefalográficas (EEG) [7]. Usualmente, las señales epilépticas cerebrales son divididas en cuatro estados (Figura 1.1): interictal (entre un ataque epiléptico y otro), pre-ictal (antes de un ataque epiléptico), ictal (durante un ataque epiléptico) y post-ictal (después de un ataque epiléptico) [4], [7], [8]. Así, la transición entre la etapa ictal y pre-ictal garantiza el suceso de una convulsión.

Entre las técnicas que se han utilizado para realizar la predicción de convulsiones se tienen métodos probabilísticos y matemáticos, y métodos de Inteligencia Artificial (IA) [5], [8], [9]. Sin embargo, no se ha realizado suficiente énfasis en el sentido temporal del problema. Esto puede deberse al hecho de




Figura 1.1: Etapas de las señales epilépticas cerebrales características [9].

que los modelos actuales no explotan lo suficiente la naturaleza temporal de las EEG. En este sentido, las Redes Neuronales Pulsantes (SNN, por sus siglas en inglés) sobresalen en las aplicaciones de reconocimiento de patrones espacio-temporales (STPR, por sus siglas en inglés)[10], [11], [12] tal y como la predicción de ataques epilépticos basado en señales EEG representa. Lo anterior se debe a su gran manejo de la información y adaptación a las variaciones temporales[11].

Parte fundamental del funcionamiento de estas redes radica en el modelo neuronal con el que se construyan sus nodos. Dentro de la gran variedad de modelos que se han propuesto, el modelo de Integración y Disparo con Fugas (LIF, por sus siglas en inglés) es uno de lo más utilizados en la literatura actual dado su fácil manejo y funcionamiento óptimo [13].

Por otro lado, el construir y entrenar SNN puede ser una tarea de extrema complejidad. Parte del problema surge de la imposibilidad de modificar las SNN con métodos clásicos de la IA y que la misma estructuración manual de los nodos puede llevar a sobrestimar o subestimar el número de unidades necesarias dadas las capacidades del modelo que las rigen. Así, la Neuroevolución (NE), como método del Cómputo Evolutivo (EC, por sus siglas en inglés), puede aliviar esta complicación.

En términos generales, la NE genera búsquedas de redes neuronales óptimas para una tarea específica [14], [15]. Dentro de esto, se puede llegar a considerar la modificación de los pesos, su estructura y su ordenamiento. Uno de los métodos más utilizados de NE es el de Neuroevolución de Topologías de Aumento (NEAT, por sus siglas en inglés).

La idea central de esta propuesta consiste en aprovechar la ventaja inherente de SNN en aplicaciones STPR y utilizar NEAT como medio de búsqueda de SNN competitivas. De tal forma, el objetivo de esta tesis es neuroevolucionar

SNN capaces de mejorar el tiempo de anticipación de un ataque epiléptico a partir de señales EEG.

1.1. Propuesta

En este trabajo, se propone una arquitectura tipo SNN para la predicción de ataques epilépticos a partir de señales EEG mediante la clasificación de las etapas interictal y pre-ictal para detectar la información de entrada y cambios temporales necesarios que evidencien el comienzo inminente de una convulsión. Las capacidades computacionales del modelo LIF han sido probadas en las SNNs [16], [17]. De tal forma, la red propuesta estará constituida por este tipo de neuronas. Asimismo, se utilizará NEAT como método de NE para encontrar una SNN que provea de resultados competitivos.

1.2. Justificación

La predicción de ataques epilépticos representan un problema basado, altamente, en el tiempo. Por lo tanto, se requiere una solución dirigida a la precisión del dominio temporal, como lo son las SNN. Así, beneficiarse de la esencia dinámica y asincrónica de estas redes permitirá tomar en cuenta nuevas variables; a saber, el momento de pulso, la frecuencia del mismo y su latencia. Por otro lado, NEAT se ha utilizado como método neuroevolutivo, proporcionando una herramienta eficiente y probada para la obtención de redes competitivas. Con lo antes mencionado, se supera la dificultad del entrenamiento de este tipo de redes. Así, se puede obtener un procedimiento sinérgico, robusto y eficaz.

1.3. Hipótesis

El modelo SNN neuroevolucionado será capaz de lograr una predicción de un ataque epiléptico con una anticipación estadísticamente superior a los modelos existentes en el estado del arte, preservando el rango de clasificación de dichos métodos con una arquitectura compacta.

1.4. Objetivos

1.4.1. General

Implementar un modelo SNN neuroevolucionado para la predicción de ataques epilépticos utilizando señales EEG.

1.4.2. Particulares

1. Realizar una etapa de preprocesamiento de las señales EEG mediante el algoritmo de Ben's Spiker Algorithm (BSA, por sus siglas en inglés) [18].
2. Construir un modelo SNN constituido por neuronas LIF.
3. Lograr la neuroevolución por medio de NEAT.
4. Clasificar los estados interictal y pre-ictal a partir de señales EEG.
5. Reportar los valores obtenidos.

1.5. Estructura del documento

El resto del documento esta organizado en los siguientes capítulos:

Capítulo 2 contiene los conceptos teóricos principales y el contexto del problema para comprender el trabajo mostrado.

Capítulo 3 detalla la revisión de la literatura realizada en dos frentes: el uso IA en la predicción de ataques epilépticos y la implementación de métodos de cómputo evolutivo y neuroevolución para el entrenamiento de SNN.

Capítulo 4 presenta la metodología adoptada para el trabajo. Ahí se engloba la base de datos utilizada, las etapas de preprocesamiento, experimentación y resultados.

Capítulo 5 muestra, con mayor detalle, los experimentos ejecutados, así como los resultados alcanzados en estos.

Capítulo 6 finaliza con las conclusiones obtenidas a partir de la observación de los experimentos y la evidencia de los resultados, dando diferentes propuestas de trabajo futuro derivados de esta propuesta.

2 Marco Teórico

2.1. Epilepsia

La epilepsia es uno de los trastornos neurológicos más comunes, afectando aproximadamente a 50 millones de personas en todo el mundo [2]. Adicionalmente, cerca del 80 % de los casos se encuentran en países de medianos y bajos recursos.

Definida por la Asociación Mundial de la Salud (WHO, por sus siglas en inglés), la epilepsia es una enfermedad crónica, no transmisible, caracterizada por el padecimiento frecuente de ataques epilépticos [2]. A su vez, estos episodios están descritos como eventos de descarga eléctrica excesiva que tiene lugar en un grupo de células cerebrales [2], [5] y pueden ser categorizados a partir de los síntomas que se presenten; una convulsión parcial (focal) o una convulsión generalizada [19], [20]. La primera categoría describe episodios donde solo una sección de un hemisferio cerebral se ve afectado, mientras que el paciente permanece consciente sin la habilidad de poderse comunicar (parcial simple) o exhibe un comportamiento irracional (parcial complejo). En la segunda categoría, todas las regiones del cerebro se ven afectadas y el paciente puede llegar a convulsionar [21], [22].

Existe una gran variedad de medicamentos anticonvulsivos que han mostrado buenos resultados para prevenir o aminorar la frecuencia de las convulsiones [23]. Sin embargo, muchas veces este tratamiento no logra eliminar por completo las convulsiones [24]. Por otra parte, los mejores resultados a este tipo de tratamiento están ligados con su administración oportuna, momentos antes de una convulsión. Así, uno de los grandes retos que implica vivir con este padecimiento es la incertidumbre implícita de sufrir una convulsión en lugares públicos o potencialmente peligrosos. En este sentido, se ha reportado que este es uno de los aspectos que más afecta a los pacientes en su calidad de vida [23].

2.2. Electroencefalografía

Entre las técnicas más comunes para la visualización y el estudio de los ataques epilépticos están la Tomografía por emisión de Positrones, la Resonancia Magnética Funcional y la Electroencefalografía. Esta última es muchas veces preferida por su alta sensibilidad al dominio temporal, su bajo costo y su portabilidad [7].

La electroencefalografía es un método electrofisiológico que permite registrar la actividad eléctrica cerebral [7], [21]. Específicamente, las señales EEG (Figura 2.1) son producto de la suma de potenciales post-sinápticos de un grupo de neuronas corticales activándose sincronamente cerca de la superficie cerebral. Así, estas señales son captadas por medio de un grupo de electrodos situados en la superficie del cráneo, donde cada electrodo puede registrar, aproximadamente, 6 cm^2 de actividad cortical [7] en un periodo de tiempo.




Figura 2.1: Ejemplo de un conjunto de señales EEG comunes [25].

Para tener un manejo homogéneo y estandarizado, existe nomenclatura internacional que guía el número y posición de los electrodos en el cráneo para la electroencefalografía. De los más utilizados en la medicina está la estrategia 10-20 [7] (Figura 2.2). Este estándar maneja una disposición de los puntos con relación a las posiciones anatómicas, que puede ser del 10 % o 20 % de intervalos entre cada uno. En consecuencia, cada electrodo recibe una letra y número en correspondencia con el lóbulo cerebral que abarca.




Figura 2.2: Diagrama del estándar 10-20. Para cada electrodo, la letra representa el lóbulo cerebral que abarca (F para frontal, P para parietal, T para temporal, O para occipital y C para central). Los números impares son asignados al lado izquierdo y los pares al lado derecho. La letra z marca los puntos sobre la línea media del cráneo y la letra A son posicionados en las orejas de ambos lados. Los nodos de color negro representan puntos neutros para la toma de mediciones [7].

2.3. Redes Neuronales Pulsantes

Las redes neuronales artificiales (ANN, por sus siglas en inglés) están conformadas por un conjunto de unidades computacionales (“neuronas”) en un sistema ordenado por capas con valores de activación continuos y entradas ponderadas [26], [27]. Por sí solas, las ANNs son equiparables a máquinas de procesamiento. Sin embargo, no son capaces de adaptarse a un conjunto de información. Así, necesitan de un proceso de aprendizaje. En este caso, el factor de aprendizaje se refiere a un conjunto de modificaciones aplicadas a la red que la fuerzan a exhibir un comportamiento particular [27]. La retropropagación, una de las técnicas más comunes para esta tarea, consiste en minimizar una función de error por medio del ajuste de los valores de los pesos que conforman la red [26], [27].

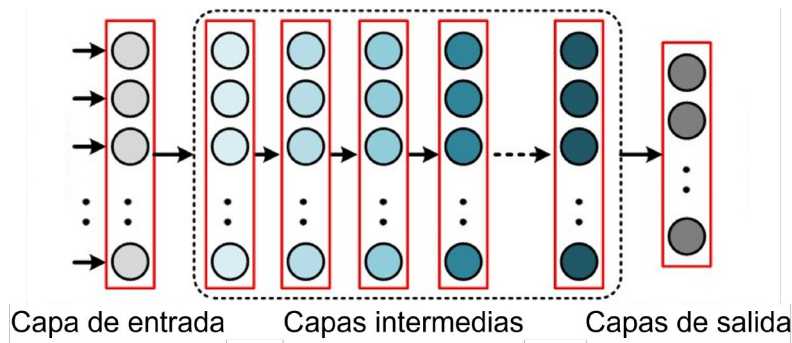


Figura 2.3: Ejemplo de una red neuronal profunda (Modificado de [11]). Los cuadros rojos representan diferentes capas de la red. Los nodos significan unidades computacionales.

El surgimiento de herramientas computacionales potentes y de alto rendimiento, tal como las Unidades de Procesamiento Gráfico (GPUs, por sus siglas en inglés), ha permitido añadir más capas de neuronas artificiales a las ANNs, obteniendo mejoras en el rendimiento y precisión de estas [11]. Las Redes Neuronales Profundas (Figura 2.3) han tenido éxito en diversas áreas como el reconocimiento por visión [28], [29], [30], [31], reconocimiento de voz [32] y biomedicina [33], por nombrar algunas. Sin embargo, este tipo de redes no consideran el componente temporal de algunas aplicaciones. Consecuentemente, investigadores han dirigido sus esfuerzos a las Redes de Gran Memoria a Corto Plazo (LSTM, por sus siglas en inglés), las cuales son consideradas dentro del conjunto de Redes Neuronales Recurrentes (RNNs, por sus siglas en inglés).

Las LSTMs (Figura 2.4) permiten conexiones de retroalimentación entre neuronas, incorporando un mecanismo de memoria en la red. Así, las LSTM han mostrado buenos resultados en aplicaciones de STPR [34]. Sin embargo, este tipo de redes son susceptibles a un gradiente inestable y a un efecto de saturación de información [12] a medida que las redes crecen y las secuencias de entrada se alargan. Como resultado, se han realizado esfuerzos para utilizar SNNs, la tercera generación de ANNs.

Introducidas en 1997 por Wolfgang Maass [10], las SNNs son una aproximación biológica más realista, en comparación con generaciones pasadas, respecto a la propagación de información. En el cerebro, la interacción entre neuronas sucede mediante la transmisión intermitente de potenciales de acción, señales




Figura 2.4: Ejemplo de una LSTM [35]. Aquí, C corresponde a la memoria de la red, mientras que H y X representan las salidas y entradas, respectivamente. Las celdas en amarillo indican ANN simples con la función de activación correspondiente. Los puntos rosas son operaciones puntuales.

de tren de pulsos, a otras neuronas cercanas [11] (Figura 2.5). Consecuentemente, las neuronas envían información en forma de pequeños pulsos eléctricos solo cuando han recibido suficiente de estos [36]. Esta característica ofrece la habilidad de capturar dinámicas temporales complejas [37].




Figura 2.5: Esquema de la interacción biológica entre neuronas (Modificado de [38]). Los pulsos viajan de una neurona a otra por medio del axón. Las conexiones que establecen se conocen como sinapsis.

La arquitectura de una SNN (Figura 2.6) incorpora neuronas pulsantes y pesos escalares ajustables que representan las sinapsis, interconectando las unidades en la red [11]. De tal forma, parte clave del funcionamiento de este tipo de redes esta determinado por el modelo neuronal de los nodos.




Figura 2.6: Una estructura SNN general completamente conectada. Los nodos azules representan neuronas y están regidos por algún modelo neuronal. Tanto las salidas como las entradas están dadas por medio de señales pulsantes.

2.4. Modelos neuronales

Cualquier modelo neuronal pulsante ofrece las siguientes propiedades:

- Procesar la información proveniente de cualquier entrada conectada y generar un solo pulso como salida.
- La probabilidad de generar un pulso se incrementa con entradas excitatorias (positivas) y decrece con entradas inhibitorias (negativas).
- La dinámica de activación de la neurona debe de estar caracterizada por, al menos, una variable la cual representa un valor umbral.

Existe una gran cantidad de modelos neuronales que cumplen con estas propiedades y que han sido utilizados como unidades computacionales. Dentro de los más relevantes, y cercanos al verdadero funcionamiento de una neurona real, se tiene el modelo Hodgkin-Huxley, el modelo Izhikevich y el modelo LIF.

Dentro de los mencionados, el modelo más utilizado actualmente es el de LIF [9], [13]. El funcionamiento de esta representación se basa en la relación entre el voltaje de membrana (voltaje interno de la neurona), el tiempo y las conexiones de la neurona (Figura 2.7). De esta forma, la neurona permanecerá en un valor de descanso siempre y cuando no reciba ningún pulso. En caso contrario, el voltaje podrá aumentar o disminuir en caso de que el pulso llegue por

una conexión positiva (excitatoria) o negativa (inhibitoria), respectivamente. Asimismo, existe una fuga de voltaje mientras la neurona no reciba un nuevo pulso, denotando una tendencia a regresar a su punto de descanso. De tal forma, la sucesión de pulsos dentro de un periodo de tiempo corto ocasionará que el voltaje alcance un valor de umbral, el cual determina el disparo de un pulso en la salida de la neurona. Posterior a esto, la neurona entra en un periodo refractario donde no acepta el ingreso de pulsos y, en consecuencia, no se modifica su voltaje. Este periodo termina una vez que la neurona retoma su valor de descanso.

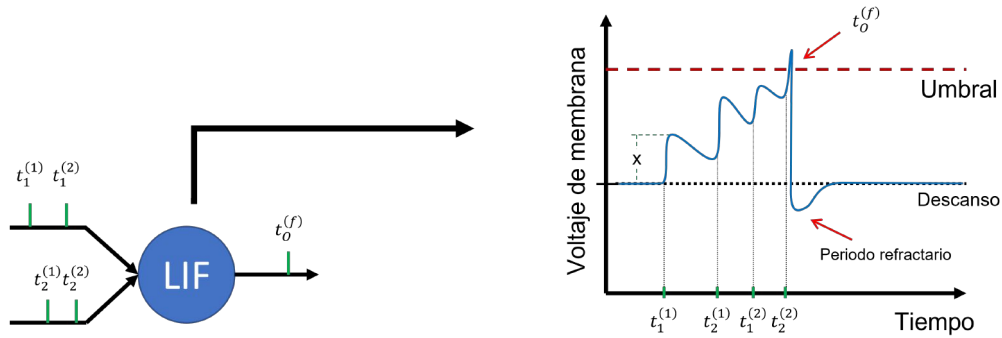


Figura 2.7: Gráfica del modelo neuronal LIF. La línea continua representa los valores de voltaje de la neurona. La línea punteada en negro marca el valor de voltaje de descanso, mientras que la línea punteada en rojo denota el valor de umbral. Las líneas verdes representan los pulsos que entran y salen de la neurona. El aumento de voltaje X estará relacionado al peso de la conexión que transporta el pulso de entrada.

Así, la información se transmite por la sincronización de pulsos. Esto incluye las propiedades de latencia y tasa de picos [11], [38]. En consecuencia, los pulsos en un SNN son distribuidos en el tiempo, logrando una propagación de información más rápida [36]. Por ende, un solo pulso o una pequeña variación temporal pueden producir diferentes resultados, lo cual denota una gran sensibilidad hacia las aplicaciones STPR [10].

En este mismo contexto, el aprendizaje (en este caso es comúnmente llamado como plasticidad sináptica) se refiere a la capacidad de cambiar la fuerza de las conexiones sinápticas entre neuronas [13]. El método más común de aprendizaje es la Plasticidad Dependiente del Tiempo de Pulsos (STDP, por sus

siglas en inglés). Su objetivo es generar un ajuste a los pesos que conectan a dos neuronas pre y post sináptica de acuerdo al tiempo relativo de sus pulsos generados. En consecuencia, el comportamiento de la neurona es alterado para generar un patrón de pulsos esperado [11].

Sin embargo, el entrenamiento de las SNNs representa un desafío, ya que los trenes de pulsos son representados mediante la suma de funciones delta de Dirac ¹. En consecuencia, es difícil implementar una optimización basada en derivaciones dado que no existe la derivada de la función [11]. Algunos procesos de optimización han sido utilizados para superar esta situación en [26], [39] y [40].

Por otro lado, existe una complejidad asociada a la construcción manual de estas redes. Definir una estructura, las capas y el número de nodos en cada una de ellas puede derivar en un procedimiento de experimentación extenso y, en algunos casos, poco intuitivo. Para aliviar esta problemática, existen aproximaciones interesantes en el EC [41], [42].

2.5. Cómputo Evolutivo

Siendo una parte fundamental de la IA, el EC ha tenido una consolidación importante como técnica de optimización y modelado para diversos problemas complejos [43]. Su principal objetivo es el de utilizar métodos adaptativos con el propósito de realizar una tarea dada. Dentro del amplio conjunto de temas que abarca, los Algoritmos Evolutivos (EA, por sus siglas en inglés) poseen gran relevancia.

Los EA toman inspiración en procesos evolutivos naturales, tal como la supervivencia del más apto.

De manera general, se tiene en cuenta un conjunto de soluciones potenciales a un problema específico, en donde una solución puede ser mejor que otra bajo un criterio específico (función de aptitud). Mediante la competencia entre los individuos, se van eliminando y sustituyendo soluciones en cada ejecución

¹La función delta de Dirac expresa una distribución sobre los número reales y es comúnmente utilizada para modelar un solo pico (pulso). Así, la suma de estas funciones es utilizada para replicar trenes de pulsos que simulan un respuesta neuronal en un periodo de tiempo.

(generación) del algoritmo. De lo anterior, se pueden definir los elementos de un EA (Figura 2.8) [43]:

- **Inicio:** Un EA, en su forma más general, debe de tener como punto de partida la inicialización de individuos. En esta etapa, se realiza la codificación de las posibles soluciones (o fenotipos) reales, en términos del problema que se busca solucionar, a individuos (o genotipos) que formarán la población dentro del EA. De tal forma, la inicialización puede ser realizada de manera aleatoria o siguiendo un esquema de muestreo.
- **Población:** La principal función de la población es la de almacenar a los individuos durante todo el proceso. De tal forma, la población es la unidad que pasa por un proceso de adaptación mediante la creación, reemplazo y modificaciones que sus individuos van experimentado. La diversidad es una forma de estimar las diferencias entre los individuos en una población y, por tal motivo, expresa el alcance que tiene el EA en la exploración del espacio de búsqueda ².
- **Selección de padres:** El mecanismo de selección de padres dictamina que individuos podrán generar descendencia. Esta decisión es, típicamente, probabilista y basada directamente en su calidad (función de aptitud); ente más aptos, los individuos tendrán mayor probabilidad de convertirse en padres. De tal forma, lo que se busca aprovechar son las mejores cualidades de los individuos.
- **Padres:** Este puede ser considerado como un subgrupo de la población conformada por aquellos individuos que fueron seleccionados por los criterios correspondientes.
- **Operadores de variación:** Este mecanismo tiene como objetivo generar nuevos individuos a partir de individuos ya existentes (Padres) y se dividen en dos: Cruza (Reproducción) y Mutación.
 - **Cruza (Reproducción):** El operados de cruza busca combinar características de dos o más padres. Para su funcionamiento, se aplican estrategias estocásticas que determinan que información es

²En el contexto de optimización, se le conoce como espacio de búsqueda a todos los posibles puntos que le dan solución al problema [43]

tomada de cada padre. Por tal motivo, este operador fomenta la explotación del espacio de búsqueda.

- **Mutación:** El operador de mutación busca realizar modificaciones aleatorias a un individuo, obteniendo uno nuevo con algunas ligeras alteraciones. De tal manera, este operador fomenta la exploración del espacio de búsqueda.
- **Hijos:** Este conjunto contiene a los nuevos individuos generados por los operadores de variación.
- **Reemplazo (Selección de sobrevivientes):** Este mecanismo evolutivo se encarga de decidir que individuos pueden continuar a la siguiente generación, teniendo en cuenta a los hijos recién creados. Típicamente, estos métodos se basan en conservar las soluciones con los mejores valores de aptitud y, por lo tanto, suelen ser deterministas. Como consecuencia, el reemplazo también permite tener un tamaño de población constante durante todo el proceso evolutivo.
- **Término:** El final de un EA debe de estar definido por algún criterio específico. Esto puede estar dado por un número determinado de generaciones (evaluaciones), un tiempo máximo de cómputo, una ausencia de mejoras en las aptitudes en un determinado tiempo o por que se encontró una solución conocida y deseada, entre otras.

Dada la gran versatilidad de estos métodos, se han generado un número importante de implementaciones en diferentes dominios. En este sentido, la estructuración de redes neuronales mediante EC tiene lugar en la NE [41], [42].

2.6. Neuroevolución

La NE puede ser descrita como una técnica de la IA que alinea el uso de EA para la búsqueda de redes neuronales, con el objetivo de optimizar el desempeño de estas, para una tarea específica [44]. Existen diferentes parámetros en donde la NE puede operar, y pueden ser agrupados de manera general en tres niveles principales [45]: pesos, topología (arquitectura) y reglas de aprendizaje.

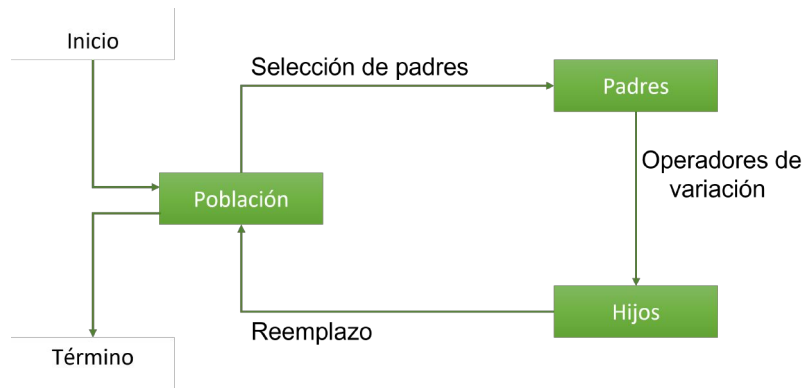


Figura 2.8: Esquema general de un EA (Modificado de [43]). Las letras en negro representan mecanismos y funciones propias del EA, mientras que los cuadros en verde muestra los grupos de soluciones que se van considerando en cada etapa. Las flechas muestran el proceso que sigue el EA.

Por otro lado, existen algunos métodos que engloban más de una categoría. A estos algoritmos de NE se les conoce comúnmente como Red Neuronal Artificial de Evolución de Topología y Pesos (TWEANN, por sus siglas en inglés), donde se combina la generación progresiva de arquitecturas con la modificación de los pesos de las redes neuronales. Dentro de estos métodos se encuentra el de NEAT.

Introducido por Stanley & Miikkulainen [14], NEAT surge como un método de NE que combina la evolución de arquitecturas con la búsqueda de los pesos de conexión para cada red neuronal generada, utilizando como EA base un Algoritmo Genético (GA, por sus siglas en inglés).

Una parte importante de NEAT radica en su expresión genotípica (codificación genética), la cual determina la implementación de los operadores de cruza-mutación y su red neuronal correspondiente (representación fenotípica). Todo genoma contiene una lista de “genes de conexión”, donde cada uno de ellos se refiere a dos “genes de nodos” conectados. Así, los “genes de conexión” especifican un nodo de entrada, un nodo de salida, su peso asociado, su estado (habilitado o deshabilitado) y un número de innovación [46] (Figura 2.9). Este último parámetro permite al algoritmo tener un registro histórico y creciente del origen de un gen, solucionando el problema de cruzar dos individuos con

estructuras diferentes (convenciones en competencia). En general, podemos describir NEAT en tres partes fundamentales: Mutación, Cruza y Especiación.

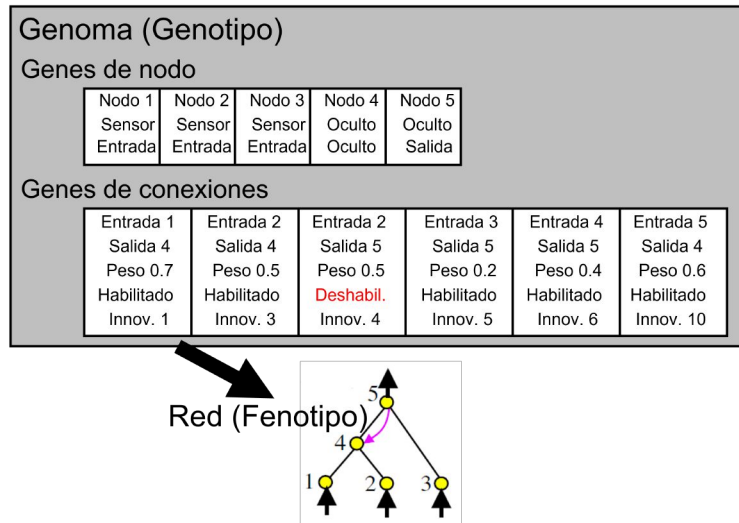


Figura 2.9: Estructura genotípica y su representación fenotípica de NEAT (Modificado de [46]). Los genes de conexión especifican la estructura de la red neuronal.

2.6.1. Mutación

NEAT es capaz de mutar tanto el valor de los pesos como la estructura de una red. Primero, la mutación de los pesos sucede por medio de una perturbación del valor actual de una conexión durante cada generación. Segundo, la mutación estructural (Figura 2.10) está determinada de dos maneras:

- Mutación de “Agregar Conexión”.
Una conexión, con peso aleatorio, es creada entre dos nodos no conectados.
- Mutación de “Agregar Nodo”.
Inicia con la inserción de un nuevo nodo en una conexión existente. Esta conexión es deshabilitada, dando lugar a dos nuevas conexiones. La nueva conexión que entra al nuevo nodo tendrá un peso igual a 1, mientras que la nueva conexión que sale del nuevo nodo recibirá el peso de la vieja conexión.

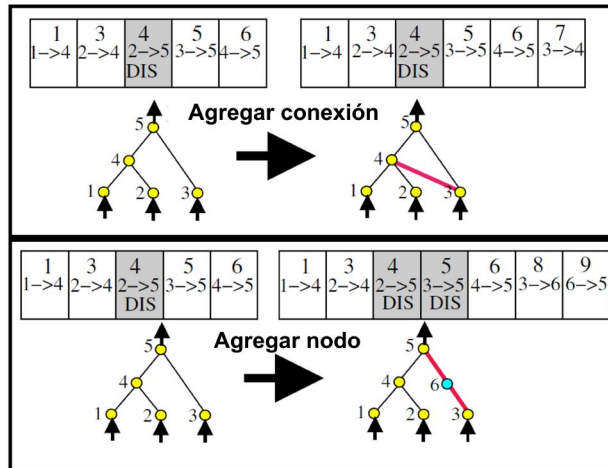


Figura 2.10: Dos tipos de mutación estructural (Modificado de [46]). La mutación de “Agregar Conexión” (arriba) añade una conexión entre dos nodos previamente desconectados. La mutación “Agregar Nodo” (abajo) modifica una conexión, sustituyéndola por un nodo y dos conexiones (una entrante y otra saliente).

Dado que estas mutaciones modifican la constitución del gen, todas las nuevas conexiones creadas tendrán un número de innovación crecientemente diferente, conservando la cronología de genes creados por el sistema [14]. Es importante destacar que, mediante las mutaciones estructurales, los genes (y, por ende, las redes neuronales) irán creciendo gradualmente de tamaño.

2.6.2. Cruza

En NEAT, la cruza está fuertemente determinada por el número de innovación y tiene lugar a partir de dos padres. Así, este operador se convierte en un problema de alineación entre los números de innovación de los genes que conforman los padres (Figura 2.11). A los genes que están presentes en ambos padres se les conoce como genes coincidentes. Por otro lado, aquellos genes que no coinciden son considerados disjuntos o excedentes, dependiendo de los rangos de los números de innovación de los padres. Este tipo de genes representan estructuras ausentes en los genomas a cruzar [14].

Una vez que todos los genes son alineado en orden, la cruza puede llevarse a

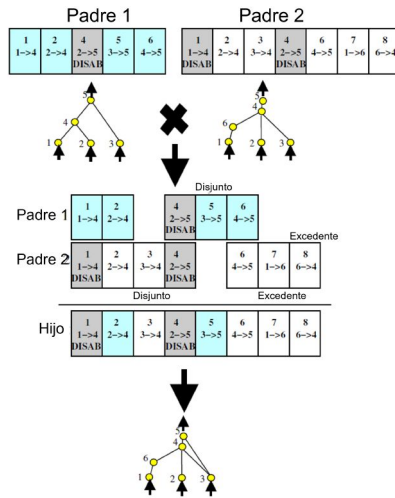


Figura 2.11: Operador de cruce de NEAT (Modificado de [46]). La alineación de los genes permite la combinación de estructuras inicialmente distintas.

cabo. Para los genes coincidentes, uno de ellos es escogido de manera aleatoria de alguno de los padres. En el caso de los genes disjuntos o excedentes, estos son heredados del padre más apto, o de manera aleatoria si ambos tienen la misma aptitud [46].

2.6.3. Especiación

La adición de nuevas estructuras (conexiones o nodos) a una red puede resultar, inicialmente, en una reducción del valor de aptitud [46]. De manera que nuevos individuos tienen poca probabilidad de sobrevivir las generaciones suficientes para demostrar si la innovación que presentan es crucial en la solución del problema dado [14]. Para dar solución a esto, NEAT integra el procedimiento de especiación de la población.

El número de genes disjuntos y excedentes entre dos individuos es un forma simple de detectar diferencias significativas entre dos individuos. Es decir, entre mayor diferencia hay entre dos genomas, menos compatibles serán. Por lo tanto, la distancia de compatibilidad (δ) de dos genomas puede ser establecido como la combinación lineal del número de genes disjuntos (D) y excedentes (E), así como la diferencia promedio de los pesos de genes coincidentes (\bar{W})

[46]:

$$\delta = \frac{c_1 E}{N} + \frac{c_2 D}{N} + c_3 \cdot \overline{W} \quad (2.1)$$

Donde c_1 , c_2 y c_3 ponderan el impacto de los factores y N (número de genes en el genoma más largo) normaliza la dimensión del genoma.

La colocación de los individuos en diferentes especies está determinado por un valor de umbral δ_t . Si la δ entre un nuevo individuo y un miembro de una especie es menor a δ_t , entonces el individuo es situado en dicha especie. Así, los genomas compiten dentro de su propia especie en vez de enfrentarse a la población completa; las innovaciones topológicas son protegidas dándoles más tiempo de optimizar sus estructuras.

3 Marco Referencial

Diversos estudios han revisado la utilidad de las SNN en el contexto de la epilepsia, reportando modelos computacionales capaces de detectar convulsiones mediante la clasificación de distintas características entre las etapas interictal y pre-ictal [5].

Chu et al. [47] realizaron un análisis del proceso de transición de señal pre-ictal a ictal, con especial interés en los fenómenos precursores a una convulsión. Con esto, se calcularon los coeficientes de Fourier (CF) de 6 frecuencias de las señales EEG y fueron utilizadas para la predicción de convulsiones mediante un proceso de estimación por umbral. Como resultado, obtuvieron 86.67 % de sensibilidad y especificidad, con una SPH de 45.3 minutos.

De manera similar, Liu et al. [48] reportaron el uso de señales EEG para la predicción de convulsiones utilizando el dominio de la frecuencia y el tiempo. Para la primera, realizan una conversión de las señales utilizando la transformada rápida de Fourier (FFT, por sus siglas en inglés) y para la segunda, utilizan las señales EEG directas. Ambas son alimentadas a una arquitectura Multi-view tipo Red Neuronal Convolutiva (CNN, por sus siglas en inglés) con dos capas convoluciones ReLU de 516 y 256, una capa fully connected con 128 nodos tipo tanh y una última capa tipo Softmax para la predicción. En sus resultados muestran una sensibilidad de 91.5 % y una especificidad del 79.5 %, con una mínima SPH de 5 minutos.

Por otro lado, Wei et al. [49] publicaron su trabajo utilizando un red convolutiva recurrente a largo plazo (LRCN, por sus siglas en inglés). La estructura contempla 5 capas convolucionales de 32, 64, 128 y 512 para la extracción de características de las señales, seguida de un bloque de LSTM 512 unidades. Los resultados de su trabajo fueron estipulados en 81.88 % y 86.13 % para la sensibilidad y especificidad, respectivamente. También, reportaron un SPH de 21 minutos.

Una aproximación un tanto diferente es la mostrada por Ibrahim et al. [50]. En ella, realizan la predicción de convulsiones mediante distribuciones de probabilidad estadística. Para ello, extrajeron las funciones de densidad de probabilidad (PDF, por sus siglas en inglés) para las ocurrencias de convulsiones utilizando diferentes ventanas de tiempo. Una vez hecho esto, utilizaron una estructura a base de umbrales para su predicción, similar a [47]. Los resultados obtenidos no fueron alejados a los del Wei et al. [49].

Usman et al. [51] reportaron el uso de la Transformada de tiempo corto de Fourier (STFT, por sus siglas en inglés) para la conversión de las señales del dominio del tiempo al dominio de frecuencias. Así, utilizaron una CNN de dimensiones 65, 117, 23 y 2 para la extracción de características de entrada y, para la predicción, utilizaron una máquina de soporte vectorial (SVM, por sus siglas en inglés). Los resultados mostraron un 92.7 % de sensibilidad y 90.8 % de especificidad, con un SPH de 21 minutos.

Posterior a este trabajo, Usman et al. [52] utilizaron una CNN personalizada de tres capas (16 x 16 x 32) para la extracción preliminar de características. De ahí, el entrenamiento fue realizado mediante un ensamble de clasificadores (SVM, CNN y LSTM) utilizando un Modelo de meta-aprendizaje agnóstico (MAML, por sus siglas en inglés). Como resultado, muestran un 93 % y 92.5 % para sensibilidad y especificidad, respectivamente, y un SPH de 32 minutos.

Por último, Aung & Wongsawat [53] mostraron una nueva técnica utilizando la entropía multivariada, llamada entropía de distribución modificada multivariante multiescala (MM-mDistEn, por sus siglas en inglés). Una vez realizado ese procedimiento, hacen uso de una ANN de dos capas con 12 neuronas cada una. Como salida, utilizan una capa softmax considerando tres casos: interictal, pre-ictal e ictal. Como resultado, reportaron 91.82 % de sensibilidad, 99.11 % de especificidad y un SPH de 26.73 minutos.

En la Tabla 3.1 se presenta el resumen de los modelos mencionados. Como se puede observar, la mayoría de las propuestas contemplan una etapa de pre procesamiento extensa, ya sea por medio del análisis de las señales (transformadas de Fourier, distribuciones de probabilidades, etc.) o mediante la selección de características (CNN). Esto puede llevar a un procedimiento menos eficiente

en términos de la automatización del problema. Asimismo, ninguna de las propuestas logra superar un SPH de 60 minutos. De hecho, la mayoría se mantiene en un rango de 30 minutos a 20 minutos. Esto es de especial interés, ya que el tiempo de previsión de una convulsión tiene un impacto significativo en los pacientes, como se mencionó anteriormente (Capítulo 2.1).

Tabla 3.1: Revisión de los modelos propuestos para la predicción de ataques epilépticos. Los valores en negritas señalan el mejor valor. Las entradas con “-” especifican datos no proporcionados.

Estudio	Año	Método	Sensibilidad	Especificidad	SPH	Dimensiones
Chu et al.[47]	2017	CF Threshold	86.67 %	86.67 %	45.3 min	-
Liu et al.[48]	2019	FFT CNN	91.5 %	79.5 %	5 min	18 x 512 x 256 x 128 x 2
Wei et al.[49]	2019	LRCN	91.88 %	86.13 %	21 min	18 x 32 x 64 x 128 x 512 x 512 x 2
Ibrahim et al.[50]	2019	PDF Threshold	90.3 %	85.2 %	22.63 min	-
Usman et al.[51]	2020	STFT CNN + SVM	92.7 %	90.8 %	21 min	18 x 65 x 117 x 23 x 2
Usman et al.[52]	2021	CNN MAML + LSTM	93 %	92.5 %	32 min	18 x 16 x 16 x 32 - 256
Aung & Wongsawat[53]	2021	MM-mDistEn ANN	91.82 %	99.11 %	26.73 min	18 x 12 x 12 x 1

Como fue mencionado anteriormente, el entrenamiento de una SNN representa un obstáculo importante. En este sentido, métodos de CE y NE han sido utilizados para superar esta dificultad. Kasabov et al. [42] presentaron un método para sobrellevar esta tarea utilizando Sistemas conexionistas en Evolución (ECOS, por sus siglas en inglés). En él, se busca evolucionar la estructura de la SNN de manera dinámica de la información entrante, partiendo de los pulsos que se van generando. Cada neurona se ve representada como una emisora de patrones la cual se va comparando con la salida esperada. Así, conforme la evolución avanza, nuevas neuronas se van creando o uniendo dependiendo de lo necesario.

Por otro lado, Stromatias et al. [54] utilizó un Algoritmo Genético (GA, por sus siglas en inglés) para realizar el entrenamiento de pesos en una SNN de alimentación hacia adelante. La constitución de los cromosomas se basa en las conexiones de nodos (sinapsis), utilizando 6 bits: 3 para los pesos y 3 para una demora en el pulso. Así, el GA es utilizado para evolucionar las conexiones de las SNN. Este método se probó con el problema del XOR, logrando obtener configuraciones que dan solución a dicho problema.

Qiu et al. [55] utilizaron NEAT como método de NE para SNNs. En su trabajo demostraron la capacidad de esta composición para problemas no lineales, en específico, el problema del equilibrio de polos (problema del péndulo invertido). Los resultados obtenidos fueron comparados con ANNs neuroevolucionadas por medio de NEAT. Así, lograron concluir que la combinación de NEAT con SNN fue más rápida en encontrar soluciones funcionales que su contraparte.

Otro método, propuesto por López-Vázquez et al. [56], plantea el uso de la Evolución Gramatical (GE). Con ello, logran abarcar modificaciones estructurales y de conexiones para SNNs. La idea general recae en la capacidad de construir gramáticas libre de contexto que incluye número de neuronas, sinapsis y sus pesos. Este método fue probado con varias base de datos conocidas (Iris, Wine, etc), llegando a demostrar que se generaban redes menos complejas con buenos resultados de clasificación.

La Tabla 3.2 presenta un resumen de los métodos revisados. Esta revisión muestra un avance significativo en la integración de SNN con métodos de CE. Sin embargo, estas referencias solo abarcan problemas controlados, es decir, bases de datos bien conocidos y trabajados. Teniendo evidencia de métodos funcionales para el entrenamiento de SNN, resulta de interés avanzar la investigación hacia problemas reales, desafiantes y caóticos.

Tabla 3.2: Revisión de métodos CE y NE existentes aplicados a SNN.

Estudio	Año	Método
Kasabov et al. [42]	2013	ECOS
Stromatias et al. [54]	2015	GA
Qiu et al. [55]	2018	NEAT
López-Vázquez et al. [56]	2019	GE

El método propuesto por Kasabov et al. [42] se enfoca en las modificaciones estructurales de la red dejando de lado la modificación numérica de las conexiones. En el caso contrario, la propuesta de Stromatias et al. [54] está orientada exclusivamente en el entrenamiento de los pesos. Por lo tanto, la estructuración de la red debe de ser conformada manualmente. Esto puede llevar

a estructuras de una complejidad innecesaria.

Por otro lado, las propuestas de Qiu et al. [55] y López-Vázquez et al. [56] consideran la modificación de la estructura y conexiones de redes, abarcando ambos frentes. Sin embargo, se debe de reconocer que con NEAT existe la posibilidad de generar una selección de características, reduciendo el número de entradas consideradas y, por lo tanto, disminuyendo la complejidad de la red.

De tal forma, la propuesta que se plantea en esta investigación hace uso de NEAT como método de neuroevolución de SNNs para un problema real, tal como lo es la predicción de ataques epilépticos, con redes cuyas estructuras sean resultado de un proceso de evolutivo.

4 Metodología

La idea principal de este trabajo se basa en el análisis de las señales EEG. De manera general, se busca detectar ondas pre-ictales, diferenciándolas de las ondas interictales. La metodología propuesta se muestra a continuación. También, se presenta un diagrama que muestra cada parte del proceso en la Figura 4.1.

4.1. Base de datos

Se utilizará la base de datos CHB-MIT [25], la cual es una de las más utilizadas en la literatura revisada. Además, sus señales son de tipo craneal (no invasivo).

Dicha base de datos consiste en señales EEG de 24 pacientes (23 pediátricos y 1 adulto) a una frecuencia de muestreo de 256 Hz. En la mayoría de los casos, las señales fueron adquiridas por medio de 23 canales respetando las posiciones descritas en el estándar 10-20 (Figura 2.2). Sin embargo, se observan algunas inconsistencias. Por ejemplo, algunas señales presentan errores de lectura o son inexistentes. En general, en todos los casos existen 18 canales persistentes. Asimismo, existe un desbalance en el número de señales sin y con evidencia de actividad epiléptica, siendo mayor la segunda. También, el ordenamiento de las señales por canal no era conciso en todos los casos. Con fines de simplicidad, en la Tabla 4.1 se muestra la relación de canales en concordancia con la señal a la que corresponden.

Por último, la base de datos está dividida en diferentes registros (archivos) por cada paciente, que van de 1 a 4 horas de duración haciendo un total de 983 horas. Todos los archivos con actividad ictal fueron anotados con el inicio y final del ataque epiléptico por expertos a partir de una inspección visual. Se identificaron 198 eventos de esta naturaleza.

Tabla 4.1: Correspondencia de canales con la señal respectiva.

Canal	Señal	Canal	Señal
0	FP1 - F7	9	F4 - C4
1	F7 - T7	10	C4 - P4
2	T7 - P7	11	P4 - O2
3	P7 - O1	12	FP2 - F8
4	FP1 - F3	13	F8 - T8
5	F3 - C3	14	T8 - P8
6	C3 - P3	15	P8 - O2
7	P3 - O1	16	FZ - CZ
8	FP2 - F4	17	CZ - PZ

4.2. Preprocesamiento

Dado que en la base de datos existen algunas inconsistencias sobre el número y orden de los canales, solo se conservarán los canales persistentes, eliminando el resto. Asimismo, solo se tendrá en cuenta 120 registros sin actividad epiléptica y 120 registros con esta actividad, con el propósito de balancear las clases. Los registros sin actividad epiléptica se caracterizan por contar solo con segmentos de señales interictales, mientras que los registros con actividad epiléptica muestran señales interictal, pre-ictal, ictal y post-ictal. Así, se realizará una segmentación de las señales con el propósito de conservar solo segmentos continuos de interictal y pre-ictal que pueden durar entre 60 y 90 minutos, para el caso de los registros con evidencia epiléptica. Aunado a esto, los registros de sin evidencia epiléptica serán segmentados en relación a una duración fija de 90 minutos. Esta etapa de procesamiento posibilitará trabajar directamente con las etapas iniciales de señales epilépticas, permitiendo detectar la transición de señal interictal a señal pre-ictal.

Por último, se realizará una transformación de las señales EEG a señales de pulsos, siguiendo la metodología descrita en [1], donde se optimizaron los parámetros del BSA por medio de una Evolución Diferencial (DE, por sus siglas en inglés).

4.3. Partición

Dos particiones serán utilizadas. La primera será destinada a la neuroevolución y la segunda para la validación. Esta selección sigue un orden de 70 % y 30 %, respectivamente. Cada señal será alojada en cada partición de manera aleatoria.

4.4. Experimentación

Existen tres métricas importantes para este propósito: la sensibilidad, la especificidad y SPH. La sensibilidad se relaciona con qué tan bien el sistema clasifica los casos positivos verdaderos y se puede expresar como se muestra en la ecuación 4.1, donde TP son los verdaderos positivos y FN son los falsos negativos. De la misma manera, la especificidad enfatiza qué tan bien el sistema está clasificando los casos negativos verdaderos y puede expresarse como se muestra en la ecuación 4.2, donde TN son los verdaderos negativos y FP son los falsos positivos. Finalmente, SPH mide el momento en que se pronostica una convulsión ($T_{deteccion}$) contra el momento real del inicio de esta ($T_{convulsion}$). Se puede expresar como se muestra en la ecuación 4.3. Cabe señalar que entre mayor SPH, mejor es la capacidad de anticipación de una convulsión.

$$Sensibilidad = \frac{TP}{TP + FN} \quad (4.1)$$

$$Especificidad = \frac{TN}{TN + FP} \quad (4.2)$$

$$SPH = T_{convulsion} - T_{deteccion} \quad (4.3)$$

Utilizando la partición de entrenamiento, se utilizará NEAT para neuroevolucionar redes SNN. Para este proceso, las redes serán inicializadas con 18 nodos de entrada, los cuales corresponden a los canales de las señales mencionados (Tabla 4.1). Asimismo, se le permitirá a la neuroevolución generar pesos

positivos y negativos, emulando las conexiones excitadoras e inhibitorias, respectivamente.

En este punto, se propone desarrollar dos experimentos con diferentes funciones de aptitud, buscando explorar dos formas de evolucionar redes: priorizando la sensibilidad y el SPH, respectivamente. Asimismo, se realizarán 5 ejecuciones por experimento con el objetivo de tener mayor evidencia que soporte las conclusiones obtenidas.

La función de aptitud del experimento 1 estará dada por la sensibilidad (Ecuación 4.1), favoreciendo la capacidad, por parte de las redes creadas, de detectar señales pre-ictales, ignorando el momento de la detección. Por otro lado, el experimento 2 tendrá como objetivo principal mejorar el SPH. Para lograr esto, se modificará la función de aptitud para que la evolución considere el momento de detección de una señal pre-ictal. El diseño de esta función se muestra en la ecuación 4.4. Dado que el valor de la sensibilidad tiene un rango de 0 a 1, es utilizado como un moderador de los valores SPH. Así, la guía de la búsqueda no solo recae en los valores de SPH, sino que también se le da importancia a la eficacia (sensibilidad) que la red evolucionada presenta.

$$f(x) = SPH * Sensibilidad \quad (4.4)$$

4.5. Resultados

Una vez terminada la neuroevolución, la clasificación será realizada mediante la partición de validación utilizando la mejor red obtenida para ambos experimentos. Esto engloba reportar las métricas mencionadas en el Capítulo 4.4: sensibilidad, especificidad y SPH. En esta última, el valor que se manejará resulta del promedio de SPH obtenido en cada señal, por lo que también se mostrará la desviación de los valores. Por último, también se anotarán las dimensiones de las mejores redes evolucionadas, contando tanto nodos de entrada como nodos intermedios.

Con el fin de tener evidencia estadística de estos resultados y observaciones, se realizarán 5 ejecuciones por experimento. Esto proporcionará las mediciones de media (\bar{x}), desviación estándar (σ) y mediana (M_e) de las ejecuciones,

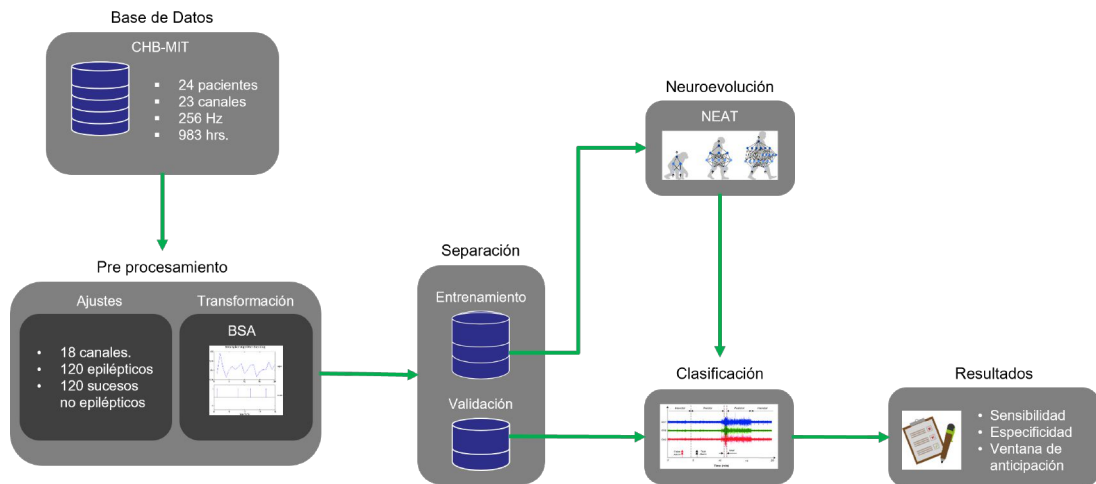


Figura 4.1: Diagrama completo de la metodología propuesta.

mostrando la consistencia de los resultados. Si bien el número de ejecuciones es bajo, es importante mencionar que cada una de ellas involucran tiempos y recursos computacionales altos. Asimismo, las ejecuciones propuestas pueden dar pie a una evidencia preliminar que conduzca a la realización de más experimentos.

También se analizará el proceso de neuroevolución evaluando las gráficas de convergencia, el comportamiento de las especies y las estructuras de las redes finales generadas para cada experimento. En consecuencia, se podrá tener un entendimiento del proceso evolutivo observado en las ejecuciones realizadas.

5 Experimentos y resultados

En esta sección se aborda la descripción de los dos experimentos realizados y su procedimiento. También se resumen los resultados obtenidos. Como se mencionó anteriormente (Capítulo 4.4), la única diferencia entre ambos experimentos radica en la función de aptitud utilizada para la neuroevolución. Así, mientras el primer experimento se enfoca exclusivamente en la sensibilidad, el segundo incorpora la rapidez de la predicción (SPH).

5.1. Parámetros utilizados

Los parámetros utilizados, para ambos experimentos, son mostrados en la Tabla 5.1. Cabe señalar que los parámetros utilizados fueron seleccionados por un proceso de prueba y error. Dada la complejidad del método de neuroevolución, se acotó la cantidad de individuos, dándole prioridad al número de generaciones, es decir, permitir a los individuos evolucionar por más tiempo. Además, se buscó desalentar el estancamiento de las especies, eliminando toda aquella que no mostrara avances 3 generaciones.

En la sección de reproducción, se puede observar que solo un individuo por especie es preservado en cada generación, fomentando la diversidad de las redes. Por otro lado, el 40% de los individuos (por especie) se somete al proceso de reproducción.

En cuanto a los valores de mutación, favorecieron las modificaciones que agregaran nodos o conexiones para tener redes más complejas y robustas. Es importante puntualizar que la mutación de eliminar un nodo se dejó considerablemente baja. Esta decisión fue tomada para cuidar los nodos iniciales de su eliminación.

Por último, los parámetros de especiación establecen que solo una especie es preservada en cada generación (Elitismo de especie). Además, el umbral que determina la distancia de compatibilidad (Capítulo 2.6.3) se estableció en 2.4.

Tabla 5.1: Parámetros utilizado para ambos experimentos.

Parámetro		Valores
General	Población	30
	Generaciones	400
	Estancamiento máximo	3
Reproducción	Elitismo	1 c/especie
	Umbral	40 %
Mutación	Agregar conexión	60 %
	Eliminar conexión	40 %
	Agregar nodo	60 %
	Eliminar nodo	20 %
	Reemplazar valor	80 %
Especiación	Elitismo	1
	Tamaño mínimo	1
	Umbral	2.4

5.2. Entorno de ejecución

Para la realización de estos experimentos, se utilizó una computadora Intel Core i5-10300H CPU and 8 GB RAM, bajo el lenguaje de programación Python 3.9. Las librerías utilizadas fueron las de BindNET [57] para la simulación de SNN y NEAT-Python [58] para la neuroevolución. A la par, se utilizaron métodos disponibles en la librería de PyTorch [59]. Los códigos creados están disponibles en GitHub, bajo la liga <https://github.com/CarlosLpzH-91/NESNN>.

5.3. Experimento 1: Enfoque en sensibilidad

5.3.1. Neuroevolución

Los resultados de las ejecuciones de neuroevolución se muestran en la Figura 5.2. Como resultado, se obtuvo una media de 88.22 % (± 3.23) en sensibilidad y 53.14 (± 2.02) minutos de SPH. Asimismo, los mejores valores fueron obtenidos durante la ejecución 4 y la mediana en la ejecución 3 y 1 para estas métricas, respectivamente.

Tabla 5.2: Resultado de las ejecuciones de neuroevolución del experimento 1. Los valores en negritas señalan el mejor valor. Los valores en itálica representan la mediana.

Métrica	Sensibilidad	SPH
Ejecución 1	89.46 %	<i>50.86 min</i>
Ejecución 2	84 %	48.21 min
Ejecución 3	94.12 %	53.14 min
Ejecución 4	88 %	48.56 min
Ejecución 5	85.12 %	51.02 min
\bar{x}	88.14 % \pm 3.99	50.36 min \pm 2.02 min

El comportamiento de la aptitud en población junto con el mejor individuo durante las cinco neuroevoluciones se puede visualizar en la Figura 5.1. También, se muestra el comportamiento de las especies en la Figura 5.2. En ella, cada especie es representada con un color diferente y es posible visualizar el número de individuos que pertenecen a cada una de las especies en cada generación. Más aún, por medio de estas gráficas se expone el momento de creación y extinción de especies, lo cual es un proceso importante en la neuroevolución. Por último, en la Figura 5.3 se observan a los mejores individuos evolucionados por NEAT.

En la Figura 5.1 se puede apreciar una tendencia ascendente respecto a la aptitud por generación en todas las ejecuciones. Sin embargo, también se observa un comportamiento errático. Esto se puede explicar por el parámetro de estancamiento máximo. Es decir, no se está permitiendo que los individuos permanezcan mucho tiempo en la evolución, dando pie a más diversidad en la población. Este hecho se ve sustentado con el análisis de las especies (Figura 5.2). Ahí, existe mayor creación y eliminación de especies durante las primeras generaciones y, conforme la evolución avanza, las especies se van reduciendo y permanecen por más tiempo.

También, se puede observar que las ejecuciones 1 y 3 obtuvieron mayor variación respecto a la aptitud y, al mismo tiempo, lograron los mejores resultados en la neuroevolución.

Por otro lado, se puede visualizar la composición de las mejores SNNs evolucionadas en la Figura 5.3. Si bien no existe una entrada eliminada en común, se puede observar que la entrada 10 no se tomó en consideración para tres de

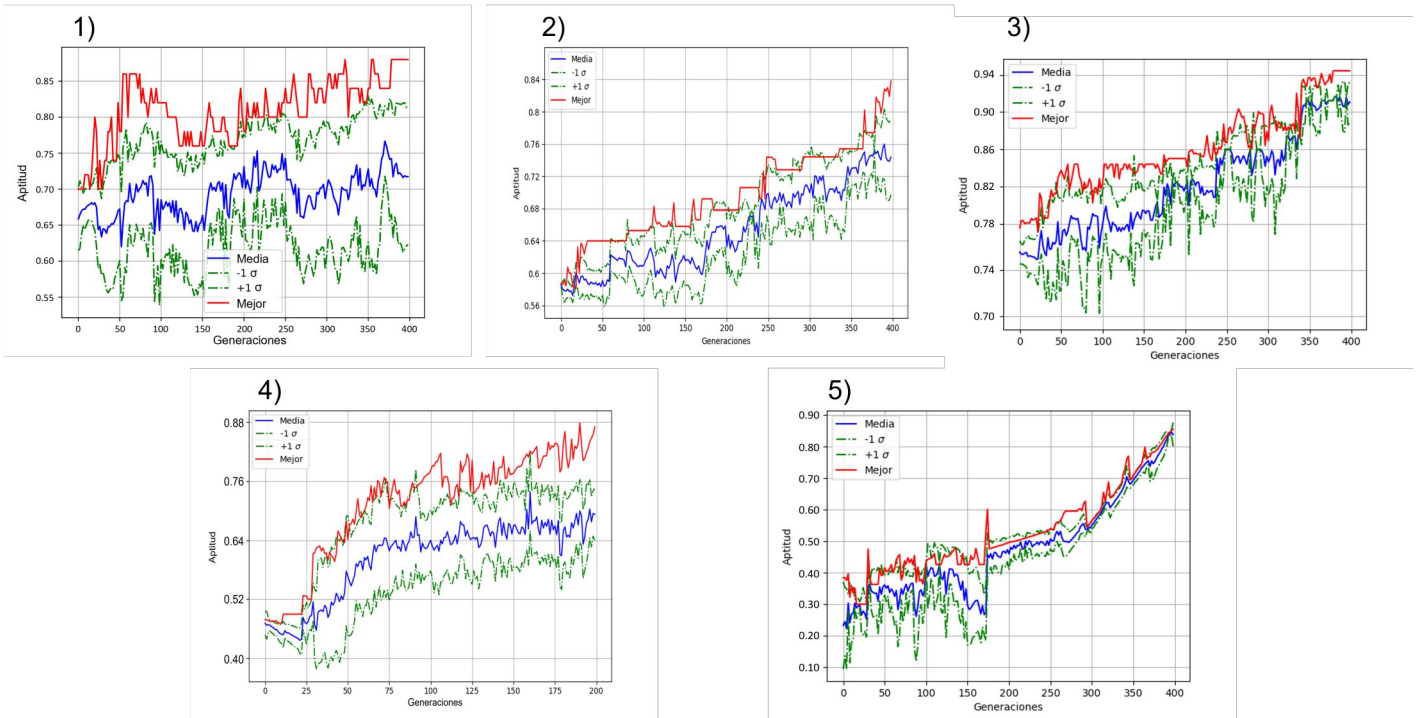


Figura 5.1: Gráficas de aptitud durante la neuroevolución para el experimento 1. Cada figura muestra el comportamiento para cada ejecución.

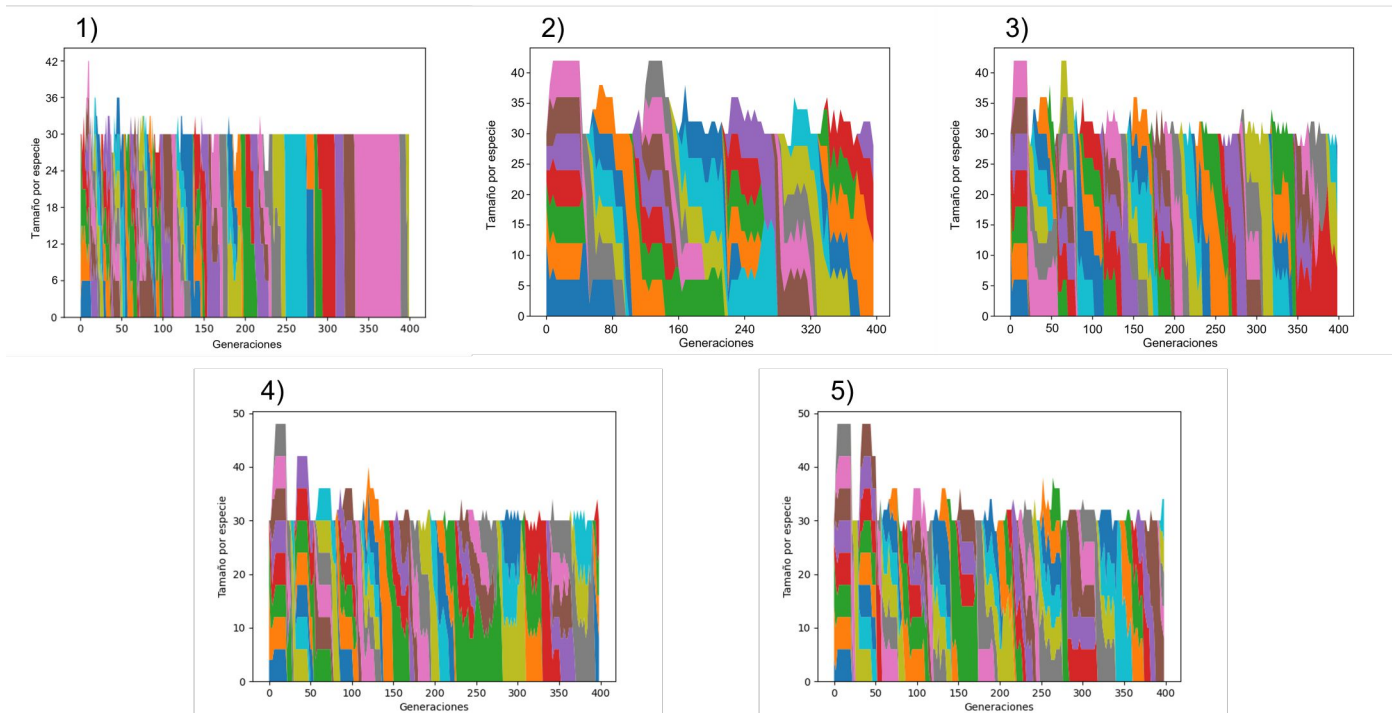


Figura 5.2: Comportamiento de las especies durante la neuroevolución para el experimento 1, mostradas en orden de ejecución. Cada color representa una especie diferente, por lo que es posible visualizar el origen y término de cada especie.

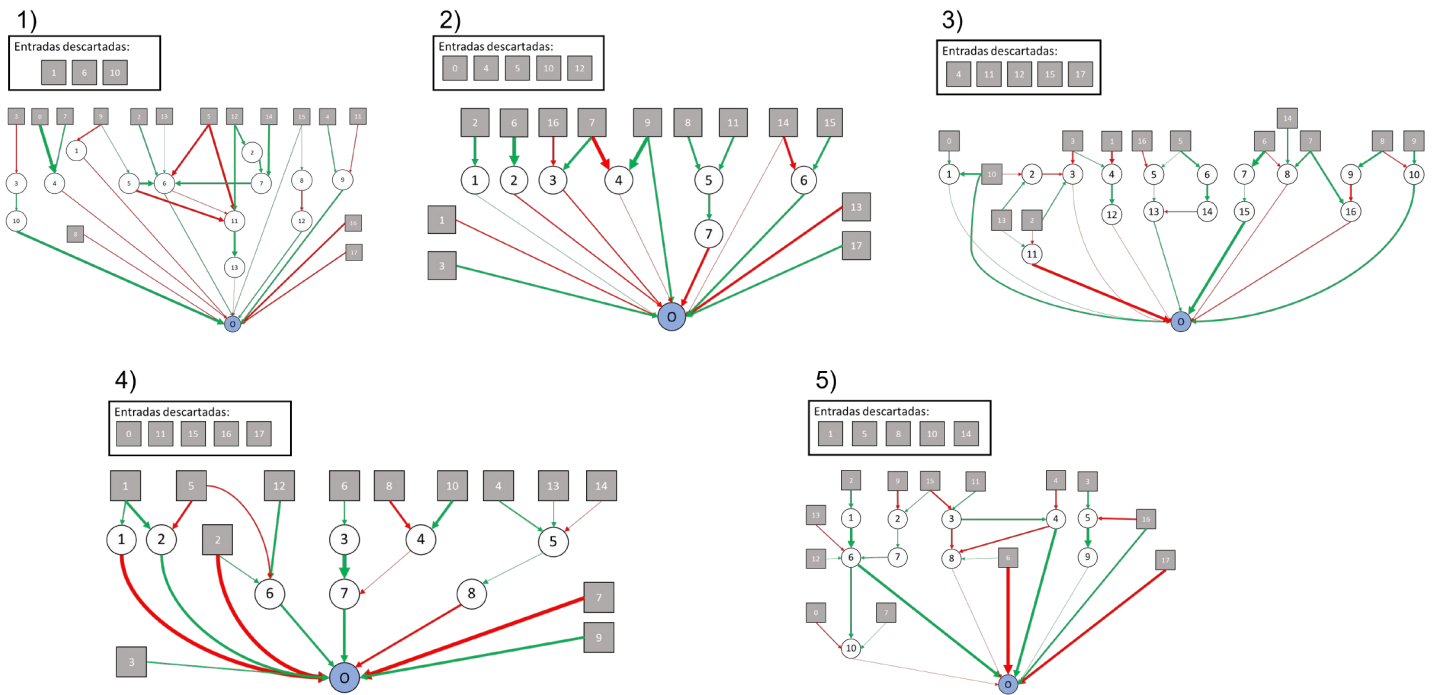


Figura 5.3: Mejores redes SNN neuroevolucionadas para el experimento 1, mostradas en orden de ejecución. Los cuadros en gris representan las entradas a la red mientras que los círculos en blanco y azul representan los nodos intermedios y de salida, respectivamente. Las conexiones excitatorias (positivas) son marcadas con verde y las inhibitorias (negativas) en rojo.

las cinco ejecuciones (Ejecución 1, 2 y 5). Asimismo, las entradas constantes fueron 2, 3, 7, 9 y 13. En cuanto al tipo de conexiones, se aprecia un balance entre las conexiones positivas y las conexiones negativas.

5.3.2. Validación

El resumen de los valores obtenidos durante la validación para las cinco ejecuciones se muestra en la Tabla 5.3.

Tabla 5.3: Resultado de la validación para las ejecuciones del experimento 1. Los valores en negritas señalan el mejor valor. Los valores en itálica representan la mediana.

Métrica	Sensibilidad	Especificidad	SPH	Dimensiones
Ejecución 1	<i>90.02 %</i>	86.45 %	<i>48.10 min</i>	15 x 13 x 1 (29 nodos)
Ejecución 2	86.15 %	76.74 %	30.36 min	13 x 7 x 1 (21 nodos)
Ejecución 3	94.20 %	<i>79.63 %</i>	45.74 min	13 x 16 x 1 (30 nodos)
Ejecución 4	89.11 %	88.57 %	50.34 min	13 x 8 x 1 (22 nodos)
Ejecución 5	92.48 %	76.88 %	49.12 min	<i>13 x 10 x 1 (24 nodos)</i>
\bar{x}	90.392 % \pm 3.11	81.654 % \pm 5.52	44.732 min \pm 8.21 min	25.2 nodos \pm 4.01 nodos

De estos datos, la media fue de 90.392 % (\pm 3.11), 81.654 % (\pm 5.52) y 44.732 (\pm 8.21 min) para la sensibilidad, especificidad y SPH, respectivamente. En este sentido, la ejecución 3 logró obtener la mejor sensibilidad y la mediana de especificidad. Esto concuerda con lo observado durante la neuroevolución, donde la ejecución 3 superó a las demás. Sin embargo, este buen desempeño no fue observado para el SPH.

Por otro lado, la mediana de SPH se posicionó en la primera ejecución. Esto resulta consistente con lo observado durante la neuroevolución (Tabla 5.2), donde la mediana del SPH también se situó en la primera ejecución.

Tabla 5.4: Resultado de las ejecuciones de neuroevolución del experimento 2. Los valores en negritas señalan el mejor valor. Los valores en itálica representan la mediana.

Métrica	Sensibilidad	SPH
Ejecución 1	82.13 %	62.13 min
Ejecución 2	86.02 %	64.35 min
Ejecución 3	85.89 %	59.87 min
Ejecución 4	76 %	56.22 min
Ejecución 5	<i>83.42 %</i>	<i>60 min</i>
\bar{X}	82.63 % \pm 4.03	60.51 min \pm 3.02 min

5.4. Experimento 2: Enfoque en SPH

5.4.1. Neuroevolución

En la Tabla 5.4 se muestran los resultados bajo el conjunto de entrenamiento. La neuroevolución logró una media de 82.63 % (\pm 4.03) y 60.51 min (\pm 3.02) para la sensibilidad y SPH, respectivamente. Los mejores resultados fueron obtenidos en la ejecución 2, mientras que la media se posicionó en la ejecución 5 para ambas métricas.

La Figura 5.4 muestra la gráfica de las aptitudes de la población, así como la de los mejores individuos de las ejecuciones. El comportamiento de las especies se puede visualizar en la Figura 5.5. De manera similar que para el experimento 1, las especies están representadas en colores diferentes, posibilitando la identificación del número de individuos que pertenecen a cada especie en cada generación. Por último, en la Figura 5.6 se observa la configuración de los mejores individuos evolucionados.

Al igual que en el experimento 1, se pueden observar una tendencia ascendente en la aptitud en todas las ejecuciones (Figura 5.4). Por otro lado, el comportamiento de crecimiento observado resulta más compacto y constante. Esto puede indicar que, a diferencia del experimento 1, los individuos permanecen mayor tiempo en la población. En otras palabras, el espacio de búsqueda resulta de mayor complejidad, por lo que es más difícil encontrar mejores individuos. Respecto a las especies, el comportamiento concuerda con el anterior. Se tiene una mayor creación de individuos en generaciones tempranas.

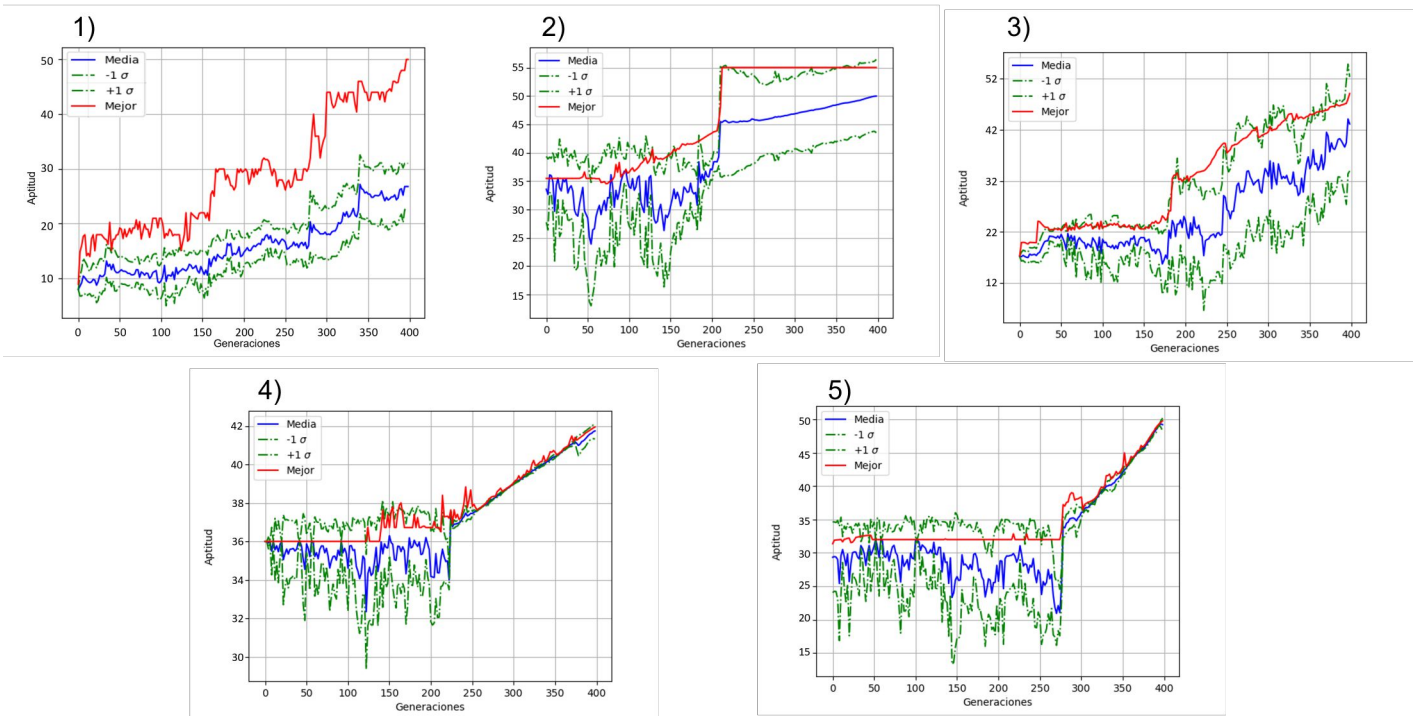


Figura 5.4: Gráficas de aptitud durante la neuroevolución para el experimento 2. Cada figura muestra el comportamiento para cada ejecución.

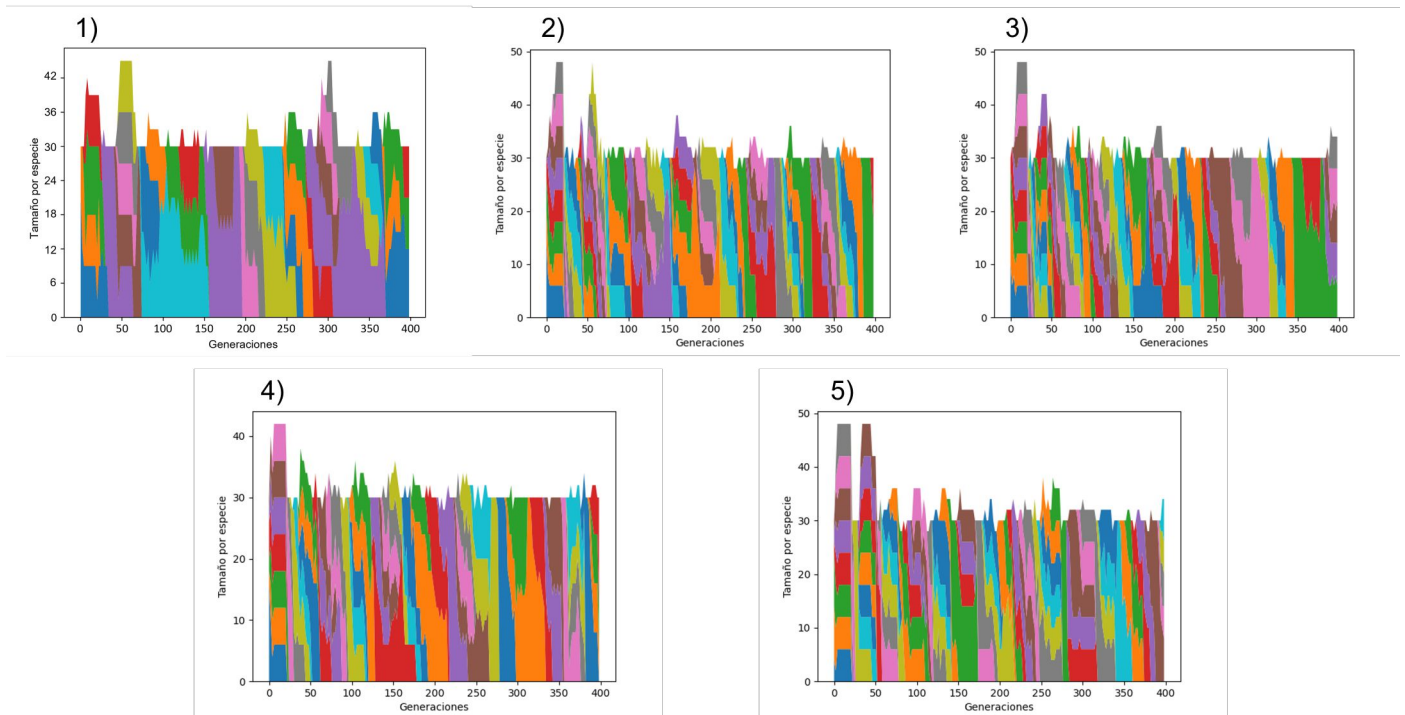


Figura 5.5: Comportamiento de las especies durante la neuroevolución para el experimento 2, mostradas en orden de ejecución. Cada color representa una especie diferente, por lo que es posible visualizar el origen y término de cada especie.




Figura 5.6: Mejores redes SNN neuroevolucionadas para el experimento 2, mostradas en orden de ejecución. Los cuadros en gris representan las entradas a la red mientras que los círculos en blanco y azul representan los nodos intermedios y de salida, respectivamente. Las conexiones excitatorias (positivas) son marcadas con verde y las inhibitorias (negativas) en rojo.

También, las ejecuciones 2 y 3 mantienen una mayor variación en generaciones finales, respecto a las otras. Asimismo, esas mismas ejecuciones obtuvieron los mejores resultados en la neuroevolución. Esto coinciden con el comportamiento del experimento pasado.

En lo que concierne a las mejores redes evolucionadas, se muestra que las entradas 1, 4, 6 y 10 fueron eliminadas en 3 de las 5 ejecuciones. Más aun, las entradas 0, 3 y 12 fueron constantes en todas las ocurrencias. Por otro lado, queda evidente que la neuroevolución formó una predisposición a la creación de conexiones positivas.

5.4.2. Validación

En la Tabla 5.4, se muestran los valores obtenidos en la validación de las cinco ejecuciones.

Tabla 5.5: Resultado de la validación para las ejecuciones del experimento 2. Los valores en negritas señalan el mejor valor. Los valores en itálica representan la mediana.

Métrica	Sensibilidad	Especificidad	SPH	Dimensiones
Ejecución 1	82.05 %	78.53 %	58 min	13 x 9 x 1 (23 nodos)
Ejecución 2	84.77 %	81.31 %	<i>59 min</i>	<i>15 x 8 x 1 (24 nodos)</i>
Ejecución 3	83.26 %	80 %	62.73 min	11 x 12 x 1 (24 nodos)
Ejecución 4	<i>82.93 %</i>	78.87 %	60.64 min	13 x 10 x 1 (24 nodos)
Ejecución 5	79.30 %	<i>79.08 %</i>	55 min	11 x 7 x 1 (19 nodos)
\bar{x}	82.46 % \pm 2.02	79.56 % \pm 1.12	59.07 min \pm 2.90 min	22.8 nodos \pm 2.17 nodos

Como se puede observar, la media fue de 82.46 % (\pm 2.02) para la sensibilidad, 79.56 % (\pm 1.12) en la especificidad y 59.07 min (\pm 2.90) de SPH. Al igual que en la neuroevolución, la ejecución 2 logró un buen desempeño, obteniendo la mejor sensibilidad, la mejor especificidad y la mediana de SPH. Por otro lado, el mejor SPH fue durante la ejecución 3.

Por un lado, se logró superar los valores de SPH del experimento 1. Sin embargo, los valores de sensibilidad y especificidad fueron más bajos. Esto indica que se mejoró la capacidad de anticipación de la predicción, pero que la capacidad de detectar los casos realmente verdaderos disminuyó.

5.5. Comparación con la literatura revisada

En la Tabla 5.6 se presenta la comparación entre ambos experimentos con los revisados en la literatura. Asimismo, la Figura 5.7 muestra el comportamiento de los resultados de sensibilidad y SPH.

Tabla 5.6: Comparación de los experimentos realizados con los revisados en la literatura. Los valores en negritas señalan el mejor valor. Las entradas con “-” especifica datos no proporcionados. Asimismo, \bar{x} , M_e y S representan la media, mediana y los mejores resultados de las ejecuciones para cada experimento, respectivamente.

Estudio	Sensibilidad	Especificidad	SPH	Dimensiones
Chu et al.[47]	86.67 %	86.67 %	45.3 min	-
Liu et al.[48]	91.5 %	79.5 %	5 min	916 nodos
Wei et al.[49]	91.88 %	86.13 %	21 min	1268 nodos
Ibrahim et al.[50]	90.3 %	85.2 %	22.63 min	-
Usman et al.[51]	92.7 %	90.8 %	21 min	225 nodos
Usman et al.[52]	93 %	92.5 %	32 min	256 nodos
Aung & Wongsawat[53]	91.82 %	99.11 %	26.73 min	43 nodos
Experimento 1 (S)	94.20 %	88.57 %	50.34 min	21 nodos
Experimento 1 (\bar{x})	90.392 %	81.654 %	44.732 min	25.2 nodos
Experimento 1 (M_e)	90.02 %	79.63 %	48.10 min	24 nodos
Experimento 2 (S)	84.77 %	79.56 %	62.73 min	19 nodos
Experimento 2 (\bar{x})	82.46 %	79.08 %	59.07 min	22.8 nodos
Experimento 2 (M_e)	82.93 %	79.08 %	59 min	24 nodos

Como se puede observar, las sensibilidades mostradas en el experimento se encuentran dentro de los rangos de la literatura revisada. Incluso, el mejor valor obtenido supera a estos valores. Por otro lado, los resultados del experimento 2 quedaron por abajo del rango inferior.

De manera similar, el experimento 1 alcanzó los rangos de especificidad de los modelos revisados del estado del arte, mientras que solo el mejor valor del experimento 2 logró alcanzar dicho rango. Sin embargo, la mejor especificidad de 99.11 % reportada por Aung & Wongsawat[53].

En cuanto al SPH, ambos experimentos superaron a la literatura revisada, logrando aumentar el tiempo de anticipación a 62.73 minutos en el caso de la




Figura 5.7: Comportamiento de la sensibilidad y SPH. Los puntos en azul representan los valores de los modelos del estado del arte, mientras que los puntos en verde y rojo marcan los resultados obtenidos de los experimentos 1 y 2, respectivamente.

mejor ejecución del experimento 2. La excepción se observó en la media del experimento 1. De la misma manera, es evidente que los SPH del experimento 2 superan al experimento 1. Esto tiene sentido dado que, en el segundo, la función de aptitud tuvo en consideración esta métrica.

Por último, ambos experimentos obtuvieron redes SNN con un menor número de nodos, disminuyendo las dimensiones de los trabajos revisados.

Por la Figura 5.7, podemos observar el comportamiento de los valores de sensibilidad y SPH. En general, se puede ver que existe una proporcionalidad inversa, donde para los mejores valores de sensibilidad, el SPH disminuye y viceversa. Asimismo, la mayoría de los modelos revisados del estado del arte sobresalen en sensibilidad, obteniendo un SPH menor. Por otro lado, esta Figura permite visualizar el posicionamiento de los resultados del experimento 1, conservando los rangos de sensibilidad y aumentando el SPH al mismo tiempo. En el caso contrario se tienen los resultados del experimento 2. Se logra observar una clara separación de estos resultados, aumentando en SPH y bajando en sensibilidad.

6 Conclusiones y Trabajo futuro

En este documento se trabajó bajo el objetivo de generar un modelo capaz de predecir el inicio de ataques epilépticos mediante señales EEG, buscando aumentar el horizonte de las predicciones. Así, una predicción más temprana se puede sustentar en la evidencia encontrada en las señales EEG, como la transición de la etapa interictal a pre-ictal. En consecuencia, la anticipación de este tipo de eventos puede ayudar en la previsión de accidentes, administración de medicamentos apropiados o como una alerta a personal médico.

Para lograr esto, se propuso combinar el uso de SNN con NEAT como método de neuroevolución para diferenciar señales pre-ictales y señales inter-ictales. Así, se evolucionaron redes tipo SNN y, una vez obtenida la mejor red, se validó con la partición correspondiente. Asimismo, se propusieron dos experimentos para manejar dos funciones de aptitud diferentes: en el primero se consideró solamente la sensibilidad y en el segundo se trabajó también con el SPH. Para contar con evidencia estadística, se realizaron 5 ejecuciones por experimento, permitiendo observar el comportamiento de cada uno de ellos.

La base de datos utilizada, CHB-MIT, fue clasificada en señales con y sin evidencia de actividad epiléptica por especialistas [25]. De ahí, se segmentaron dichas señales en instancias con ondas interictales y pre-ictales e instancias que solo contienen ondas interictales. Con esto, se logró trabajar directamente con casos donde el ataque epiléptico es y no es inminente, respectivamente. Asimismo, las particiones de la base de datos fueron realizadas de manera aleatoria y siguiendo una selección de 70 % para el entrenamiento y 30 % para la validación. Por otra parte, los parámetros utilizados para NEAT fueron obtenidos mediante un proceso experimental.

En primera instancia, se pudo observar un correcto funcionamiento con las simulaciones de las SNN y la neuroevolución mediante NEAT, logrando tener un método funcional para el propósito buscado.

En el primer experimento se utilizó, como función de aptitud, la sensibilidad

reportada por las redes. Con ello, se dio prioridad a detectar señales pre-ictales, ignorando la anticipación de la predicción. Durante el entrenamiento, NEAT logró generar redes con una sensibilidad media de 90.392 %, 90.02 % de mediana y la mejor métrica de 94.20 %. A su vez, dichas redes reportaron un SPH medio de 44.732 minutos, mediana de 48.10 minutos y el mejor SPH de 50.34 minutos. El análisis de las gráficas de aptitud (Figura 5.1) refleja una evolución congruente, en donde se tiene una buena diversidad de individuos. De manera similar, el comportamiento de las especies (Figura 5.2) muestra que, en la etapa inicial, los individuos muestran diferencias más claras, causando la creación de más especies. Conforme la evolución inicia a converger hacia un tipo específico de red, el número de especies comienza a ser más constantes. Las redes evolucionadas (Figura 5.3) reflejan un balance entre conexiones positivas y negativas. Esto sugiere un comportamiento más reservado a la predicción con mayor SPH, necesitando mayor información antes de emitir una clasificación. Por otro lado, el nodo de entrada 10 fue descartado en 3 de las 5 SNN evolucionadas, mientras que los nodos de entrada 2, 3, 7, 9 y 13 fueron constantes para todas.

En la validación de resultados se obtuvo como mejor sensibilidad un 94.20 %, una especificidad del 88.57 % y un SPH de 50.34 minutos. Como media, la sensibilidad fue de 90.392 % (± 3.11), la especificidad de 81.654 % (± 5.52) y el SPH de 44.732 minutos (± 8.21 min). Por otro lado, las medianas de la sensibilidad, especificidad y SPH cayeron en 90.02 %, 79.63 % y 48.10 minutos, respectivamente. Para las dimensiones de las mejores redes neuroevolucionadas, se obtuvo una media de 25.2 nodos (± 4.01 nodos).

En el segundo experimento se cambió la función de aptitud para tener en consideración al SPH. Dicha fórmula se presentó en la ecuación 4.4. Ahí, la sensibilidad actúa como un moderador de los valores de SPH, dándole prioridad a aquellas redes que reporten un balance en ambas métricas. Durante el entrenamiento, se consiguió evolucionar redes con sensibilidad media del 82.63 % (± 4.03), sensibilidad mediana de 83.42 % y una sensibilidad máxima de 86.02 % (± 2.02). A su vez, dicha red reportó un SPH medio de 64.35 minutos (± 3.02 min), SPH mediana de 60 minutos y un SPH máximo de 64.35 minutos. Dadas las gráficas de aptitud (Figura 5.4) y de especies (Figura 5.5), la evolución muestra un comportamiento ascendente, pero con menor diversidad, llevando a un menor número de especies. Las redes evolucionadas (Figura 5.6) muestran una preferencia a conexiones positivas, mostrando una mayor

tendencia a realizar predicciones con menor información. De igual forma, los nodos de entrada 1, 4, 6 y 10 fueron descartados en 3 de las 5 SNN evolucionadas, mientras que los nodos de entrada 0, 3, 12 fueron constantes para todas. También, se puede reconocer que este experimento generó redes más compactas. Lo anterior va de la mano con la motivación de alcanzar un valor mayor de SPH. Es decir, entre menos neuronas internas, la información llegará más rápido a la neurona de salida, disparando en un menor tiempo.

En la validación de resultados se obtuvo como sensibilidad máxima un 84.77%, una especificidad máxima del 81.31% y un SPH máximo de 62.73 minutos. Como medias, la sensibilidad fue de 82.46% (± 2.023), la especificidad de 79.56% (± 1.12) y el SPH de 59.07 minutos (± 2.90 min). Por otro lado, las medianas de la sensibilidad, especificidad y SPH cayeron en 82.93%, 79.08% y 59 minutos, respectivamente. Para las dimensiones de las mejores redes neuroevolucionadas, se obtuvo una media de 22.8 nodos (± 2.17 nodos).

Los experimentos realizados mostraron algunos comportamientos diferentes. Primero, ambas gráficas de convergencia (Figura 5.1 y Figura 5.4) muestran una tendencia ascendente. Sin embargo, en el primer experimento se observa una mayor diversidad. Esto es explicado por la misma naturaleza de la función de aptitud, en donde una busca priorizar la sensibilidad y la otra un balance con el momento de la predicción. Es decir, la variación en los valores de sensibilidad es menor que para los del SPH. Esto también se ve reflejado en las gráficas de especies. Por un lado, se tiene que el experimento 1 plantea una preferencia a disminuir el número de especies, mientras que en el segundo experimento mantiene un número mas o menos constante.

Segundo, las redes neuroevolucionadas no comparten una configuración evidentemente parecida. El segundo experimento manifiesta una tendencia a conexiones positivas, las cuales alientan la predicción de señales pre-ictales con menor información (menor tiempo), aumentando el SPH. Por otro lado, la red del primer experimento tiene un balance entre conexiones positivas y negativas, provocando que sea necesario tener mayor información (mayor tiempo) para poder emitir un pulso de predicción, disminuyendo el SPH.

Tercero, los valores obtenidos en la validación de ambos experimentos muestran una consistencia con cada función de aptitud. En el primer experimento la sensibilidad mostró un buen comportamiento, pero con un SPH menor y

en el segundo experimento el SPH aumento, disminuyendo la sensibilidad. En cada caso, la prioridad se vio reflejada con los resultados obtenidos. Cuando se buscaron obtener mejores resultados de sensibilidad, la red evolucionó con un balanceo de conexiones, provocando un retraso en el disparo de predicción. Por otro lado, cuando la prioridad fue el SPH, la red se configuró con una tendencia a disparar antes. Esta predisposición generó un disminución en los valores de sensibilidad y especificidad. Así, se logró tener una experimentación directa con la combinación de ambas funciones, dejando como antecedente la dinámica ya descrita.

Cuarto, algunas entradas fueron eliminadas en ambas redes. De hecho, se puede observar que la entrada 10 fue descartada en 6 de las 10 ejecuciones de los dos experimentos. Asimismo, la entrada 3 fue constante en todas la ejecuciones. Esto podría ser el indicio de un proceso de selección de características, en donde la entrada 10 está siendo constantemente ignorada, mientras que la entrada 3 siempre es tomada en cuenta. Asimismo, esta observación puede tener implicaciones neurológicas dado que las entradas están relacionadas a los canales de adquisición de las señales EEG. Sin embargo, sería importante tener más evidencia que sustente este comportamiento.

En general, ambos planteamientos lograron resultados interesantes. Por un lado, el primer experimento obtuvo una sensibilidad y especificidad dentro de los rangos de los métodos revisados, incluso superando a sus contra partes en la máxima sensibilidad. Por otro lado, ambas pruebas superaron las métricas de SPH, con ventaja en el segundo experimento. Por último, ambas redes evolucionadas lograron arquitecturas más compactas, incluso con un menor número de entradas.

De lo anterior, se puede llegar a la conclusión de que el método sugerido muestra un comportamiento prometedor para la predicción de ataques epilépticos mediante señales EEG. Mediante el primer experimento, se logró probar la hipótesis planteada, manteniendo una sensibilidad dentro de los rangos revisados, aumentando el SPH y generando estructuras más compactas. Sin embargo, el resultado del segundo experimento fue insuficiente respecto a la sensibilidad. Aun así, es importante remarcar el hecho de haber aumentado el SPH, y disminuido la dimensión de la red.

Por lo anterior, pareciera ser suficiente una función de aptitud simple, como la basada en la sensibilidad del experimento 1, y aprovechar la eficiencia tem-

poral implícita en las SNNs.

Existen varias ideas que pueden complementar el trabajo presentado en este documento. Se pueden explorar mejores planteamientos para funciones de aptitud. Como se observó, el segundo experimento se desempeñó bien en términos de dimensionalidad y pronta predicción, a costo de una disminución de la sensibilidad. De tal forma, tener un mejor balance entre SPH y los valores de sensibilidad y especificidad podría permitir obtener mejores resultados. Incluso, podría ser importante explorar la optimización multiobjetivo aplicada para esta problemática.

También, se espera tener un mayor número de ejecuciones que permita fortalecer aun más la evidencia estadística en los resultados. En consecuencia, se podría dar certeza del proceso de selección de características en la neuroevolución de NEAT.

Igualmente, se podría permitirle a NEAT probar diferentes configuraciones de las neuronas pulsantes, logrando explorar un espacio de búsqueda más grande y, potencialmente, nuevas soluciones surgirían.

Asimismo, se espera que futuros trabajos investiguen la conjunción del cómputo de membrana con las simulaciones de SNN. De entrada, existen muchas similitudes conceptuales entre ambos procedimientos, de ahí que su unión podría mostrar resultados interesantes.

Referencias

- [1] Carlos-Alberto Lopez-Herrera, Héctor-Gabriel Acosta-Mesa, and Efrén Mezura-Montes. (In press). Spiking Neural Networks Codification using Bio-Inspired Computation. *3rd Workshop on New Trends in Computational Intelligence and Applications (CIAPP)*., 2022.
- [2] World Health Organization (WHO). Epilepsy, 2019.
- [3] M. P. Kerr. The impact of epilepsy on patients' lives. *Acta Neurologica Scandinavica*, 126(194):1–9, dec 2012.
- [4] Viktor K Jirsa, William C Stacey, Pascale P Quilichini, Anton I Ivanov, and Christophe Bernard. On the nature of seizure dynamics. *Brain*, 137(8):2210–2230, aug 2014.
- [5] Afshin Shoeibi, Marjane Khodatars, Navid Ghassemi, Mahboobeh Jafari, Parisa Moridian, Roohallah Alizadehsani, Maryam Panahiazar, Fahime Khozeimeh, Assef Zare, Hossein Hosseini-Nejad, Abbas Khosravi, Amir F. Atiya, Diba Aminshahidi, Sadiq Hussain, Modjtaba Rouhani, Saeid Nahavandi, and U. Rajendra Acharya. Epileptic seizures detection using deep learning techniques: A review. *International Journal of Environmental Research and Public Health*, 18(11), 2021.
- [6] Yang Si. Machine learning applications for electroencephalograph signals in epilepsy: a quick review. *Acta Epileptologica*, 2(1):5, 2020.
- [7] Erik St. Louis, Lauren Frey, Jeffrey Britton, Jennifer Hopp, Pearce Korb, Mohamad Koubeissi, William Lievens, and Elia Pestana-Knight. *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants*. American Epilepsy Society, 2016.

- [8] Sora An, Chaewon Kang, and Hyang Woon Lee. Artificial Intelligence and Computational Approaches for Epilepsy. *Journal of Epilepsy Research*, 10(1):8–17, 2020.
- [9] Theekshana Dissanayake, Tharindu Fernando, Simon Denman, Sridha Sridharan, and Clinton Fookes. Patient-independent Epileptic Seizure Prediction using Deep Learning Models. pages 1–10, 2020.
- [10] Wolfgang Maass. Networks of spiking neurons: The third generation of neural network models. *Neural Networks*, 10(9):1659–1671, dec 1997.
- [11] Amirhossein Tavanaei, Masoud Ghodrati, Saeed Reza Kheradpisheh, Timothée Masquelier, and Anthony Maida. Deep learning in spiking neural networks. *Neural Networks*, 111:47–63, mar 2019.
- [12] Aaron Voelker, Ivana Kajić, and Chris Eliasmith. Legendre Memory Units: Continuous-Time Representation in Recurrent Neural Networks. 2019.
- [13] Filip Ponulak and Andrzej Kasinski. Introduction to spiking neural networks: Information processing, learning and applications. *Acta neurobiologiae experimentalis*, 71(4):409–33, 2011.
- [14] Kenneth O. Stanley and Risto Miikkulainen. Evolving neural networks through augmenting topologies. *Evolutionary Computation*, 10(2):99–127, 2002.
- [15] R Akut and S Kulkarni. NeuroEvolution: Using Genetic Algorithm for optimal design of Deep Learning models. In *2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT)*, pages 1–6, 2019.
- [16] Kun-Chih Jimmy Chen and Tze-Ling Kuo. A Unipolar-based Stochastic LIF Neuron Design for Low-cost Spiking Neural Network. In *2021 IEEE International Conference on Omni-Layer Intelligent Systems (COINS)*, pages 1–6, Barcelona, Spain, aug 2021. IEEE.
- [17] Sayeed Shafayet Chowdhury, Chankyu Lee, and Kaushik Roy. Towards understanding the effect of leak in Spiking Neural Networks. *Neurocomputing*, 464:83–94, nov 2021.

- [18] Benjamin Schrauwen and I. Van Campenhout. BSA, a fast and accurate spike train encoding scheme. In *Proceedings of the International Joint Conference on Neural Networks, 2003.*, volume 4, pages 2825–2830. IEEE, 2003.
- [19] Mona Sazgar and Michael G Young. *Absolute Epilepsy and EEG Rotation Review*. Springer, 2019.
- [20] David J. Thurman, Ettore Beghi, Charles E. Begley, Anne T. Berg, Jeffrey R. Buchhalter, Ding Ding, Dale C. Hesdorffer, W. Allen Hauser, Lewis Kazis, Rosemarie Kobau, Barbara Kroner, David Labiner, Kore Liow, Giancarlo Logroscino, Marco T. Medina, Charles R. Newton, Karen Parko, Angelia Paschal, Pierre Marie Preux, Josemir W. Sander, Anbesaw Selassie, William Theodore, Torbjörn Tomson, and Samuel Wiebe. Standards for epidemiologic studies and surveillance of epilepsy. *Epilepsia*, 52(SUPPL. 7):2–26, 2011.
- [21] Jasper R. Daube and Devon I. Rubin. *Clinical Neurophysiology*. Oxford University Press, New York, NY, USA, third edition, 2009.
- [22] Robert S Fisher. The New Classification of Seizures by the International League Against Epilepsy 2017. *Current Neurology and Neuroscience Reports*, 17(6):48, jun 2017.
- [23] Patrick Kwan and Martin J. Brodie. Early Identification of Refractory Epilepsy. *New England Journal of Medicine*, 342(5):314–319, feb 2000.
- [24] Sriram Ramgopal, Sigride Thome-Souza, Michele Jackson, Navah Ester Kadish, Iván Sánchez Fernández, Jacquelyn Klehm, William Bosl, Claus Reinsberger, Steven Schachter, and Tobias Loddenkemper. Seizure detection, seizure prediction, and closed-loop warning systems in epilepsy. *Epilepsy and Behavior*, 37:291–307, 2014.
- [25] Ali Shoeb. Application of machine learning to epileptic seizure onset detection and treatment. *Diss. Massachusetts Institute of Technology*, pages 157–162, 2009.
- [26] Adam H. Marblestone, Greg Wayne, and Konrad P. Kording. Toward an Integration of Deep Learning and Neuroscience. *Frontiers in Computational Neuroscience*, 10, sep 2016.

- [27] Jürgen Schmidhuber. Deep Learning in neural networks: An overview. *Neural Networks*, 61:85–117, 2015.
- [28] Jian He, Kaiming and Zhang, Xiangyu and Ren, Shaoqing and Sun. Deep Residual Learning for Image Recognition. 2015.
- [29] Evan Shelhamer, Jonathan Long, and Trevor Darrell. Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4):640–651, apr 2017.
- [30] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6):84–90, may 2017.
- [31] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, and Zbigniew Wojna. Rethinking the Inception Architecture for Computer Vision. dec 2015.
- [32] Geoffrey Hinton, Li Deng, Dong Yu, George Dahl, Abdel-rahman Mohamed, Navdeep Jaitly, Andrew Senior, Vincent Vanhoucke, Patrick Nguyen, Tara Sainath, and Brian Kingsbury. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups. *IEEE Signal Processing Magazine*, 29(6):82–97, nov 2012.
- [33] Seonwoo Min, Byunghan Lee, and Sungroh Yoon. Deep learning in bioinformatics. *Briefings in Bioinformatics*, page bbw068, jul 2016.
- [34] Hassan Ismail Fawaz, Germain Forestier, Jonathan Weber, Lhassane Idoumghar, and Pierre-Alain Muller. Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*, 33(4):917–963, jul 2019.
- [35] Rishibha Sharma, Vidhi Agarwal, Sushma Sharma, and Meenakshi S. Arya. An LSTM-Based Fake News Detection System Using Word Embeddings-Based Feature Extraction. pages 247–255. 2021.
- [36] Jilles Vreeken. *Spiking neural networks , an introduction*, volume 7. Utrecht University: Information and Computing Sciences, 2002.

- [37] Aboozar Taherkhani, Ammar Belatreche, Yuhua Li, Georgina Cosma, Liam P Maguire, and T M McGinnity. A review of learning in biologically plausible spiking neural networks. *Neural Networks*, 122:253–272, 2020.
- [38] Dayeol Lee, Gwangmu Lee, Dongup Kwon, Sunghwa Lee, Youngsok Kim, and Jangwoo Kim. Flexon: A Flexible Digital Neuron for Efficient Spiking Neural Network Simulations. In *2018 ACM/IEEE 45th Annual International Symposium on Computer Architecture (ISCA)*, pages 275–288. IEEE, jun 2018.
- [39] N Anwani and B Rajendran. NormAD - Normalized Approximate Descent based supervised learning rule for spiking neurons. In *2015 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8, 2015.
- [40] Neelava Sengupta and Nikola Kasabov. Spike-time encoding as a data compression technique for pattern recognition of temporal data. *Information Sciences*, 406-407:133–145, sep 2017.
- [41] Nikola Kasabov, Valery Feigin, Zeng-Guang Hou, Yixiong Chen, Linda Liang, Rita Krishnamurthi, Muhaini Othman, and Priya Parmar. Evolving spiking neural networks for personalised modelling, classification and prediction of spatio-temporal patterns with a case study on stroke. *Neurocomputing*, 134:269–279, jun 2014.
- [42] Nikola Kasabov, Kshitij Dhoble, Nuttapod Nuntalid, and Giacomo Indiveri. Dynamic evolving spiking neural networks for on-line spatio- and spectro-temporal pattern recognition. *Neural Networks*, 41:188–201, may 2013.
- [43] A.E. Eiben and J.E. Smith. *Introduction to Evolutionary Computing*. Natural Computing Series. Springer Berlin Heidelberg, Berlin, Heidelberg, 2015.
- [44] Mohamed Yilmaz Ibrahim, Rangarajan Sridhar, T.V. Geetha, and S.S. Deepika. Advances in Neuroevolution through Augmenting Topologies – A Case Study. In *2019 11th International Conference on Advanced Computing (ICoAC)*, pages 111–116. IEEE, dec 2019.

- [45] Kristoffer Olsen. *Neuroevolution of Artificial General Intelligence: Implementation and study of a framework towards the evolution of artificial general intelligence*. Master in informatics, University of Oslo, 2020.
- [46] K.O. Stanley and R. Miikkulainen. Efficient evolution of neural network topologies. In *Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02 (Cat. No.02TH8600)*, volume 2, pages 1757–1762. IEEE.
- [47] Hyunho Chu, Chun Kee Chung, Woorim Jeong, and Kwang Hyun Cho. Predicting epileptic seizures from scalp EEG based on attractor state analysis. *Computer Methods and Programs in Biomedicine*, 143:75–87, may 2017.
- [48] Chien-Liang Liu, Bin Xiao, Wen-Hoar Hsaio, and Vincent S Tseng. Epileptic Seizure Prediction With Multi-View Convolutional Neural Networks. *IEEE Access*, 7:170352–170361, 2019.
- [49] Xiaoyan Wei, Lin Zhou, Zhen Zhang, Ziyi Chen, and Yi Zhou. Early prediction of epileptic seizures using a long-term recurrent convolutional network. *Journal of Neuroscience Methods*, 327:108395, nov 2019.
- [50] Fatma Ibrahim, Saly Abd-Elateif El-Gindy, Sami M. El-Dolil, Adel S. El-Fishawy, El-Sayed M. El-Rabaie, Moawaed I. Dessouky, Ibrahim M. Eldokany, Turkey N. Alotaiby, Saleh A. Alshebeili, and Fathi E. Abd El-Samie. A statistical framework for EEG channel selection and seizure prediction on mobile. *International Journal of Speech Technology*, 22(1):191–203, mar 2019.
- [51] Syed Muhammad Usman, Shehzad Khalid, and Muhammad Haseeb Aslam. Epileptic Seizures Prediction Using Deep Learning Techniques. *IEEE Access*, 8:39998–40007, 2020.
- [52] Syed Muhammad Usman, Shehzad Khalid, and Sadaf Bashir. A deep learning based ensemble learning method for epileptic seizure prediction. *Computers in Biology and Medicine*, 136(July):104710, sep 2021.
- [53] Si Thu Aung and Yodchanan Wongsawat. Prediction of epileptic seizures based on multivariate multiscale modified-distribution entropy. *PeerJ Computer Science*, 7:e744, 2021.

- [54] Evangelos Stromatias and John S Marsland. Supervised learning in Spiking Neural Networks with limited precision: SNN/LP. In *2015 International Joint Conference on Neural Networks (IJCNN)*, pages 1–7. IEEE, jul 2015.
- [55] Huanneng Qiu, Matthew Garratt, David Howard, and Sreenatha Anavatti. Evolving Spiking Neural Networks for Nonlinear Control Problems. In *2018 IEEE Symposium Series on Computational Intelligence (SSCI)*, pages 1367–1373. IEEE, nov 2018.
- [56] G. López-Vázquez, M. Ornelas-Rodriguez, A. Espinal, J. A. Soria-Alcaraz, A. Rojas-Domínguez, H. J. Puga-Soberanes, J. M. Carpio, and H. Rostro-Gonzalez. Evolutionary Spiking Neural Networks for Solving Supervised Classification Problems. *Computational Intelligence and Neuroscience*, 2019:1–13, mar 2019.
- [57] Hananel Hazan, Daniel J. Saunders, Hassaan Khan, Devdhar Patel, Darpán T. Sanghavi, Hava T. Siegelmann, and Robert Kozma. BindsNET: A Machine Learning-Oriented Spiking Neural Networks Library in Python. *Frontiers in Neuroinformatics*, 12, dec 2018.
- [58] Alan McIntyre, Matt Kallada, Cesar G. Miguel, Carolina Feher de Silva, and Marcio Lobo Netto. neat-python.
- [59] Adam Paszke, Sam Gross, Francisco Massa, Adam Lerer, James Bradbury, Gregory Chanan, Trevor Killeen, Zeming Lin, Natalia Gimelshein, Luca Antiga, Alban Desmaison, Andreas Kopf, Edward Yang, Zachary DeVito, Martin Raison, Alykhan Tejani, Sasank Chilamkurthy, Benoit Steiner, Lu Fang, Junjie Bai, and Soumith Chintala. Pytorch: An imperative style, high-performance deep learning library. In H. Wallach, H. Larochelle, A. Beygelzimer, F. d'Alché-Buc, E. Fox, and R. Garnett, editors, *Advances in Neural Information Processing Systems 32*, pages 8024–8035. Curran Associates, Inc., 2019.