



Tecnológico Nacional de México

Centro Nacional de Investigación y Desarrollo Tecnológico

Tesis de Maestría

Red Neuronal Pulsante para el Reconocimiento de
Imágenes de Cerebros Sanos y No-Sanos

presentada por

I.S.C. Keila Vasthi Cortés Martínez

como requisito para la obtención del grado de

**Maestra en Ciencias de la
Computación**

Director de tesis
Dr. Manuel Mejía Lavalle

Codirector de tesis
Dr. Dante Mújica Vargas

Cuernavaca, Morelos, México. Diciembre de 2018.



Cuernavaca, Morelos a 10 de enero del 2019
OFICIO No. DCC/001/2019

Asunto: **Aceptación de documento de tesis**

DR. GERARDO V. GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial de la Ing. **Keila Vasthi Cortés Martínez**, con número de control M16CE003, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis profesional titulado **“Red Neuronal Pulsante para el Reconocimiento de Imágenes de Cerebros sanos y no sanos”** y hemos encontrado que se han realizado todas las correcciones y observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

DIRECTOR DE TESIS

Dr. Manuel Mejía Lavalle
Doctor en Ciencias
Computacionales
8342472

CO-DIRECTOR DE TESIS

Dr. Dante Mújica Vargas
Doctor en Comunicaciones y
Electrónica
09131756

REVISOR 1

M.C. Gerardo Reyes Salgado
Maestro en Ciencias de la
Computación
2493370

REVISOR 2

Dr. Andrés Blanco Ortega
Doctor en Ciencias en Ingeniería
Eléctrica
6559298

C.p. M.T.I. María Elena Gómez Torres - Jefa del Departamento de Servicios Escolares.
Estudiante
Expediente

NACS/Imz





Centro Nacional de Investigación y Desarrollo Tecnológico

Cuernavaca, Mor., 10 de enero de 2019
OFICIO No. SAC/013/2019

Asunto: Autorización de impresión de tesis

ING. KELIA VASTHI CORTÉS MARTÍNEZ
CANDIDATA AL GRADO DE MAESTRA EN CIENCIAS
DE LA COMPUTACIÓN
PRESENTE

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "Red Neuronal Pulsante para el Reconocimiento de Imágenes de Cerebros Sanos y no Sanos", ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica®
"Conocimiento y tecnología al servicio de México"

DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO

C.p. M.T.I. María Elena Gómez Torres .- Jefa del Departamento de Servicios Escolares.
Expediente

GVGR/mcr



SEP TecNM
CENTRO NACIONAL
DE INVESTIGACIÓN
Y DESARROLLO
TECNOLÓGICO
SUBDIRECCIÓN
ACADÉMICA

RECIBIDO
10 ENE 2019
SERVICIOS ESCOLARES

DEDICATORIAS

A Dios, por permitirme aprender parte del funcionamiento cerebral, desde tiempos inmemorables el hombre se ha preguntado, *“¿De dónde, pues, viene la sabiduría?, ¿En qué lugar está la inteligencia?”* Job 28:12-28”, permitiéndome confirmar lo que su palabra dice: *“Tal conocimiento es demasiado maravilloso para mí; Alto es, no lo puedo comprender”* Salmos 139:6

A mis padres y hermanos, por sus consejos, palabras de aliento, su apoyo constante en la lucha de mis ideales que me ayudaron a crecer como persona. Sabemos que la vida se encuentra plagada de retos, esfuerzos y enseñanzas, en los cuáles sin duda han estado conmigo, gracias por su apoyo y comprensión, espero que se sientan orgullosos de mí, los amo.

A Juan José Rivera Sandoval, por su apoyo, amor incondicional y compartir conmigo momentos felices y difíciles a lo largo de estos años.

A mis colegas, amigos y próximos estudiantes de IA , esperando contribuir un poco a la ciencia.

AGRADECIMIENTOS

Al Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET), por la oportunidad dada y formación académica en el estudio de una Maestría en Ciencias, así como al personal docente, administrativo y auxiliar, por su gran apoyo durante mi estancia.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por haberme aceptado como becaria de tiempo completo y permitirme desarrollar este trabajo de investigación con soporte económico otorgado por dos años.

Al TECNM por su apoyo en la realización del proyecto TecNM 5683.16-P.

A mi director de tesis Dr. Manuel Mejía Lavalle, por ser apoyo, maestro y brindarme su tiempo e intelecto en el desarrollo de la misma, ayudándome a forjarme como profesionalista.

A mi codirector Dr. Dante Mújica Vargas, por sus comentarios puntuales, conocimientos y colaboraciones brindadas en el desarrollo de este proyecto.

A mi comité revisor Dr. Andrés Blanco Ortega y Dr. Gerardo Reyes Salgado, por sus valiosas observaciones, paciencia y tiempo dedicado a la corrección de la presente.

Al Mtro. David Luviano Jiménez, por su colaboración desinteresada, dedicación y ayuda brindada en la redacción de esta tesis, consejos y sugerencias.

A mis amigos, compañeros de generación y sobre todo de especialidad con los que compartí proyectos, investigaciones, desvelos, motivaciones y grandes momentos en el transcurso de la carrera que, con su amistad y confianza, ayudaron en mi desarrollo profesional.

RESUMEN

Actualmente, las Enfermedades Cerebrales- Vasculares (*BSD*) representan un grave problema de salud pública y uno de los motivos frecuentes de asistencia neurológica urgente en México. El tratamiento de emergencia de una *BSD* obedece al tipo de accidente al que pertenezca, ya sea isquémico (cuando se bloquea una arteria) o hemorrágico (involucra un sangrado en el cerebro). El uso de imágenes médicas de forma automatizada reduce el tiempo de evaluación y minimiza errores en el diagnóstico y tratamiento de éstas. La Inteligencia Artificial, ha desarrollado modelos de aprendizaje automático y de reconocimiento de patrones como las Redes Neuronales Artificiales (*ANN*), en donde diferentes investigaciones ofrecen como una alternativa de solución las del tipo Pulsante (*SNN*), siendo éstas las que proporcionan información a lo largo del tiempo mediante pulsos. Debido a la importancia del tema, en el presente trabajo de tesis, se desarrolló un análisis en la clasificación de una neurona *SNN* representada por el modelo Izhikevich, usada en el reconocimiento de imágenes cerebrales obtenidas de Imágenes de Resonancia Magnéticas, demostrando que la precisión de la clasificación del modelo propuesto puede alcanzar valores comparables a otras *ANN* como la *Multi-Layer Perceptron*. Por otra parte, se estimó mediante *Accuracy* el porcentaje de casos correctamente clasificados, cuyos resultados se compararon entre las dos *ANNs*.

ABSTRACT

Currently, Brain Stroke Diseases (BSD) represent a serious public health problem and one of the reasons for urgent neurological care in Mexico. The emergency treatment of a stroke disease is due to the type of accident to which it belongs, either ischemic (when an artery is blocked) or hemorrhagic (when involves bleeding in the brain). The use of automated medical images way reduces the evaluation time and minimizes errors in the diagnosis and treatment of these. Artificial Intelligence has developed models of automatic learning and pattern recognition such as Artificial Neural Networks (ANN), where different researches offer as solution alternative those of type Spiking (SNN), being these those that provide information throughout of time by spikes. Due to the importance of the topic, in this thesis work, an analysis was developed in the classification of a SNN neuron represented by the Izhikevich model, used in the recognition of brain images obtained from Magnetic Resonance Imaging, demonstrating that the accuracy of the classification of the proposed model can reach values comparable to other ANNs such as the Multi-Layer Perceptron. On the other hand, the percentage of correctly classified cases was estimated by Accuracy, whose results were compared between both.

ÍNDICE GENERAL

RESUMEN.....	ii
ABSTRACT.....	iii
LISTA DE FIGURAS.....	vi
LISTA DE TABLAS.....	ix
CONTENIDO DEL CD.....	xi
ACRÓNIMOS.....	xii
CAPÍTULO 1. INTRODUCCIÓN.....	1
1.1 Motivación.....	1
1.2 Descripción del problema.....	3
1.2.1 Delimitación del problema.....	4
1.2.2 Complejidad del problema.....	4
1.2.3 Hipótesis.....	6
1.3 Objetivos del proyecto de tesis.....	6
1.3.1 Objetivo general.....	6
1.3.2 Objetivos específicos.....	6
1.4 Alcances y limitaciones.....	6
1.5 Justificación y beneficios.....	7
1.6 Estructura de la tesis.....	8
CAPÍTULO 2. MARCO REFERENCIAL.....	10
2.1 Antecedentes.....	10
2.2 Estado del Arte.....	15
2.3 Discusión del Estado del Arte.....	20
CAPÍTULO 3. MARCO TEÓRICO – CONCEPTUAL.....	23
3.1 Enfermedades cerebrovasculares.....	23
3.1.1 Hemorrágica.....	23
3.1.2 Isquémica.....	24
3.2 Técnicas para el diagnóstico de enfermedades cerebrovasculares.....	25
3.2.1 Electroencefalograma (<i>EEG</i>).....	26
3.2.2 Ultrasonido Doppler (<i>UD</i>).....	27
3.2.3 Tomografía Computarizada (<i>CT</i>).....	27
3.2.4 Imagen de Resonancia Magnética (<i>MRI</i>).....	27
3.3 Análisis de imágenes.....	30
3.4 Filtrado de imágenes.....	32
3.5 Redes Neuronales Artificiales (<i>ANNs</i>).....	34
3.6 Redes neuronales artificiales pulsantes (<i>SNNs</i>).....	41
3.7 Clasificación de las <i>SNNs</i>	45

3.7.1 Modelo Izhikevich.....	46
3.7.2 Análisis del aprendizaje con una neurona Izhikevich.....	47
3.8 Discusión.....	51
CAPÍTULO 4. METODOLOGÍA DE SOLUCIÓN.....	52
4.1 Implementación y entorno de desarrollo.....	52
4.2.Pasos de la solución propuestos.....	52
4.3 Adquisición de imágenes.....	54
4.4 Preprocesamiento y eliminación de artefactos.....	55
4.5 Vector de características mediante el promediado de técnicas de filtrado.....	56
4.6 Construcción de las ANNs	58
4.7 Arquitectura de la <i>SNN</i> usando el modelo de Izhikevich.....	59
4.8 Evaluación usando la técnica de validación cruzada	61
4.9 Discusión.....	62
CAPÍTULO 5. EXPERIMENTACIÓN Y RESULTADOS.....	63
5.1 Implementación en software	63
5.2 Comparación de resultados de preprocesamiento manual y automática.....	63
5.3 Pruebas y filtrado de imágenes.....	63
5.4 Diseño de la <i>SNN</i>	64
5.5 Aprendizaje y reconocimiento de las <i>ANNs MLP</i> y <i>SNN</i>	64
5.6 Clasificación y ajuste de parámetros por porcentaje de datos.....	67
5.7 Análisis de la salida de la aplicación de <i>SNN</i>	67
5.8 Discusión.....	80
CAPÍTULO 6. CONCLUSIONES.....	82
6.1 Objetivos y alcances logrados.....	82
6.2 Conclusiones finales.....	83
6.3 Resultados del trabajo.....	88
6.4 Trabajos futuros.....	90
Referencias.....	91

Índice de Figuras

Figura	Descripción	Página
1.1	Disciplinas que abarca la Inteligencia Artificial.....	2
1.2	Delimitación del problema.....	5
1.3	Metodología general en la solución del problema de tesis.....	8
2.1	Resultados de la evaluación en segmentación de bordes para a) Lenna y b)Cameraman.....	11
3.1	Representación de una enfermedad cerebro-vascular hemorrágica. a) Ruptura que afecta el flujo sanguíneo normal destruyendo tejido cerebral. b) Ruptura de un espacio débil en la pared de un vaso sanguíneo (aneurisma).....	24
3.2	Representación de una enfermedad cerebro-vascular isquémica. Trombosis causada por la obstrucción en una vena.....	25
3.3	Señal de ondas cerebrales con EGG.....	26
3.4	Arteria cerebral media con alta presión intracraneal captada por ultrasonido Doppler.....	27
3.5	Imágenes Cerebrales: (a) <i>MRI</i> normal, (b) <i>CT</i> normal, (c) <i>CT</i> anormal.....	28
3.6	Etapas comunes (no aplicables en algunos casos) en la interpretación de imágenes médicas.....	30
3.7	Ejemplificación de la visión humana.....	30
3.8	Ejemplificación de la visión por computador.....	31
3.9	Operación de convolución para filtrado lineal en un punto de una imagen.....	33
3.10	Partes de una neurona biológica (fuente Children's Hospital Boston)	35
3.11	Neurona biológica, se observa su funcionamiento y las partes principales de su sinapsis.....	35
3.12	Ejemplificación de una sinapsis en el proceso de aprendizaje.....	36
3.13	Arquitectura de una red con conexiones hacia adelante. Se distinguen los 3 tipos de nodos que puede contener una <i>ANN</i>	37
3.14	Modelo básico de McColluch-Pitts.....	38
3.15	Perceptron de Rossenblatt.....	38
3.16	Modelo de neurona artificial estándar, $f()$ simboliza la función de activación utilizada en el aprendizaje.....	39
3.17	Clases de <i>ANNs</i> de acuerdo a su generación.....	40
3.18	Esquema de una <i>SNN</i> en (Bohte, 2003).....	41

Figura	Descripción	Página
3.19	a) Partes del funcionamiento de una neurona, b) funciones de las que se rige el umbral de disparo.....	41
3.20	Fases del proceso global de transmisión de un pulso nervioso (<i>spike</i>).....	42
3.21	Los potenciales de acción transmiten información a través de su tiempo o frecuencia.....	43
3.22	Ejemplificación del desplazamiento o flujo de información del potencial de acción.....	43
3.23	Tren de pulsos de 30 neuronas en la corteza visual de un mono.....	44
3.24	Potenciales de Acción a) Pulso en Sinapsis b) Tren de pulsos.....	44
3.25	Comparación costo-plausibilidad de diferentes modelos de <i>SNNs</i>	46
3.26	Ejemplificación de algunos potenciales de acción generados a partir del modelo de Izhikevich.....	47
3.27	Funcionamiento del modelo de Izhikevich.....	48
4.1	Metodología para los experimentos de clasificación de cerebros sanos y enfermos	53
4.2	Preprocesamiento de imágenes cerebrales.....	55
4.3	Ejemplificación de una máscara de filtrado.....	56
4.4	<i>Guide</i> en Matlab con aplicación de filtros.....	57
4.5	Arquitectura del modelo de Izhikevich mediante el cual son analizadas entradas de datos	59
5.1	<i>Accuracy</i> correspondiente al aprendizaje y reconocimiento del 90% de datos seleccionados.....	69
5.2	<i>Accuracy</i> correspondiente al aprendizaje y reconocimiento del 85% de datos seleccionados.....	69
5.3	<i>Accuracy</i> correspondiente al aprendizaje y reconocimiento del 80% de datos seleccionados.....	70
5.4	<i>Accuracy</i> correspondiente al aprendizaje y reconocimiento del 75% de datos seleccionados.....	70
5.5	<i>Accuracy</i> para el 80% de instancias seleccionadas de un total de 50 imágenes.....	71
5.6	<i>Accuracy</i> para el 85% de instancias seleccionadas de un total de 80 imágenes.....	72
5.7	<i>Accuracy</i> para el 75% de datos seleccionados de un total de 85 imágenes.....	72
5.8	<i>Accuracy</i> para el 75% de datos seleccionados de un total de 90 imágenes.....	73

Figura	Descripción	Página
5.9	<i>Accuracy</i> para el 75% de instancias seleccionadas de un total de 92 imágenes.....	73
5.10	<i>Accuracy</i> correspondiente al aprendizaje y reconocimiento del 90% de datos seleccionados.....	75
5.11	<i>Accuracy</i> correspondiente al aprendizaje y reconocimiento del 85% de los datos seleccionados.....	75
5.12	<i>Accuracy</i> correspondiente al aprendizaje y reconocimiento del 80% de los datos seleccionados.....	76
5.13	<i>Accuracy</i> correspondiente al aprendizaje y reconocimiento del 75% de los datos seleccionados.....	76
5.14	<i>Accuracy</i> para el 80% de instancias seleccionadas de un total de 50 imágenes.....	77
5.15	<i>Accuracy</i> para el 85% de datos seleccionados de un total de 80 imágenes.....	77
5.16	<i>Accuracy</i> para el 90% de datos seleccionados de un total de 80 imágenes.....	78
5.17	<i>Accuracy</i> para el 80% de datos seleccionados de un total de 85 imágenes.....	78
5.18	<i>Accuracy</i> para el 75% de datos seleccionados de un total de 85 imágenes.....	78
5.19	<i>Accuracy</i> para el 90% de datos seleccionados de un total de 90 imágenes.....	79
5.20	<i>Accuracy</i> para el 80% de datos seleccionados de un total de 90 imágenes.....	79
5.21	<i>Accuracy</i> para el 90% de datos seleccionados de un total de 92 imágenes.....	79
5.22	<i>Accuracy</i> para el 80% de datos seleccionados de un total de 92 imágenes.....	79

Índice de Tablas

Tabla	Descripción	Página
2.1	Tesis de maestría con redes artificiales de tercera generación desarrolladas en el Departamento de Ciencias Computacionales del CENIDET.....	10
2.2	Resultados de la comparación de similitud con diferentes paradigmas pulsantes.....	12
2.3	Resumen de características de filtrado de ruido impulsivo con <i>PCNN</i> y filtros tradicionales.....	13
2.4	Características de filtrado de ruido gaussiano con <i>PCNN</i> y filtros tradicionales.....	13
2.5	Comparativa de las bases de datos académicas.....	14
2.6	Información relevante de técnicas de trabajos revisados.....	15
3.1	Ventajas y desventajas de las técnicas de interpretación de imágenes cerebrales.....	28
3.2	Parámetros de la técnica de filtrado.....	32
3.3	Definición y características de filtros.....	33
3.4	Comparación entre neuronas biológicas y ANNs.....	37
3.5	Clasificación General de una <i>SNN</i>	45
3.6	Parámetros de la neurona Izhikevich.....	46
3.7	Valores de los parámetros de la neurona Izhikevich con respuesta de picos regulares.....	49
3.8	Definición de los parámetros de la neurona Izhikevich.....	50
4.1	Software utilizado en este tema de investigación.....	52
4.2	Algoritmo de la técnica de filtrado para la obtención del vector de características.....	57
4.3	Clases asociadas a las ANNs.....	58
4.4	Número de imágenes usadas en los experimentos.....	58
4.5	Parámetros de entrenamiento de una <i>SNN</i> en la clasificación de imágenes cerebrales.....	60
4.6	Algoritmo propuesto de una <i>SNN</i>	61
4.7	Matriz de confusión para el cálculo del <i>accuracy</i>	62
5.1	Resultados de la <i>SNN</i> cuando $\alpha = 0.02$	66
5.2	Resultados de la <i>SNN</i> cuando $\alpha = 0.05$	66
5.3	Resultados de la <i>MLP</i> cuando $\alpha = 0.02$ y $\alpha = 0.05$	67
5.4	Resultados cuando $\alpha = 0.02$ y $\theta = 35$ en las etapas de aprendizaje y reconocimiento.....	68

Tabla	Descripción	Página
5.5	Resultados cuando $\alpha = 0.05$ y $\theta = 40$ en las etapas de aprendizaje y reconocimiento.....	74
5.6	Análisis de los filtros aplicados.....	80
5.7	Clases asociadas a las ANNs.....	80
5.8	Los porcentajes indican el accuracy más alto generado de acuerdo al conjunto de datos usados mediante la técnica de validación cruzada, cuando $\alpha = 0.02$ y $\theta = 35$	81
5.9	Los porcentajes indican el accuracy más alto generado de acuerdo al conjunto de datos usados mediante la técnica de validación cruzada, cuando $\alpha = 0.05$ y $\theta = 40$	81
6.1	Objetivos, logros y alcances.....	82

Contenido del CD

Carpeta	Documentos
01_Tesis	Tesis.pdf Presentación.pptx
02_Imágenes MRI	Sanos Sanos sin Cráneo Stroke Stroke sin cráneo
03_Bases de Datos	BD.xlsx BD_brains.xlsx ResultadosVectores de características.xlsx Emplame_Filtros
04_Código	Aplicación C++ Matlab – Simulink -SNN_Izhikevich
05_Anexos	A_Neuronalzhikevich.doc B_SkullStripping.docx C_ComponenteVectores.docx D_FuncionesFiltrado.docx E_Vectores de características.docx F_Análisis y Clasificación filtros.docx G_Resultados_ANN_MLP.docx H_Resultados_ANN_SNN.docx
06_Artículos	COMIA 2017 -DOI_10.1109_ICMEAE.2017.30.pdf -COMIA_2017_mayo.pptx -PosterCOMIA2017.jpg ICMEAE 2017 -ISSN_1870-4069_comia2017.pdf -ICMEAE_2017_Noviembre.pptx -posterICMEAE_english.jpg

Acrónimos

Sigla	Nombre
AI	Artificial Intelligence (Inteligencia Artificial)
ANN	Artificial Neural Network (Red Neuronal Artificial)
AV	Artificial Vision (Visión Artificial)
BSD	Brain Stroke Diseases (Enfermedad Cerebro-Vascular)
BP	Back Propagation (Retropropagación)
CT	Computed Tomography (Tomografía Computarizada)
DBN	Deep Belief Network (Red de Creencia Profunda)
EEG	Electroencephalogram (Electroencefalograma)
FFBPNN	Feed Foward Back-Propagation Neural Network (Red Neuronal de Retropropagación hacia adelante)
FPCNN	Feedback Pulse-Coupled Neural Network (Red Neuronal Pulso-Acoplada de retroalimentación)
ICM	Intersecting Cortical Model (Modelo de intersección cortical)
IF	Integrated and Fire (Integración y disparo)
LIF	Leaky Integrated and Fire (Integración de goteo y Disparo)
LVQ	Learning Vector Quantization (Aprendizaje de cuantificación vectorial)
MAE	Mean Absolute Error (Error Absoluto Medio)
MLP	Multi-Layer Perceptron (Perceptron multicapa)
MRI	Magnetic Resonance Imaging (Imagen de resonancia magnética)
PCA	Principal Components Analysis (Análisis de componentes principales)
PCM	Pixel Correspondence Metric (Métrica Correspondencia Pixel)
PCNN	Pulse-Coupled Neural Networks (Red Neuronal Pulso-Acoplada)
PCNNNI	Pulse-Coupled Neural Networks Null Interconnection (Red Neuronal Pulso-Acoplada de Interconexión Nula)
PixToPix	Pixel to Pixel (Pixel a pixel)
PSNR	<i>Peak Signal-to-Noise Ratio (Relación señal / ruido pico)</i>
PSP	Potencial Post-Sináptico (Postsynaptic potential)
RBF	Radial Basis Function (Funcion de base radial)
RBM	Restricted Boltzman Machine (Máquina de Boltzmann restringida)
SCM	Spiking Cortical Model
SNN	Spiking Neural Network (Red Neuronal Pulsante)
SRM	Spike Response Model (Modelo de respuesta pulsante)
STDP	Spike-Timing-Dependent Plasticity (Plasticidad dependiente sincronizada pulsante)

CAPÍTULO 1. INTRODUCCIÓN

Se presenta una descripción del problema a resolver, su importancia y los objetivos que ahondaron en la metodología de solución, así como sus alcances y dificultades que se han identificado para lograr el desarrollo del trabajo. Se incluye la estructura del documento de tesis.

1.1 Motivación

Actualmente las Enfermedades Cerebro-Vasculares (*BSD*, por sus siglas en inglés) en México deben considerarse como un problema de salud de orden prioritario. La tendencia registrada durante los últimos años muestra un incremento continuo de mortalidad por este padecimiento que ocupó en 2010, el sexto lugar dentro de las principales causas de defunción [Casares, 2015].

Las *BSD* ocurren cuando hay afectaciones en los vasos sanguíneos del cerebro, que provoca la disminución repentina de flujo sanguíneo o el rompimiento de ellos, haciendo que la sangre se esparza entre los espacios que rodean a las células cerebrales, dando lugar a dos tipos principales de procesos llamados isquémicos y hemorrágicos [Blanco, 2011]. Aunado a esto, causan secuelas neurológicas desde leves hasta severas debido a que suelen presentarse sin previo aviso [Monge-Pereira, 2014]. Estas enfermedades comúnmente pueden diagnosticarse mediante el uso de imágenes médicas obtenidas por medio de tomografías computarizadas, ultrasonidos (como el Doppler), imágenes de resonancia magnética, electroencefalogramas, etc. [Blanco, 2011], las cuales representan un método no invasivo para su detección, por lo que es importante comprender cómo se generan las imágenes, cuál es el tratamiento que requieren, a modo de evitar algunos de los errores comunes en cuanto a su uso e interpretación, lo que ha permitido corroborar, extender y rechazar modelos teóricos acerca del funcionamiento del cerebro.

El reconocimiento de imágenes médicas de forma automatizada reduce el tiempo en la evaluación y minimiza errores en el diagnóstico y tratamiento de enfermedades [Rihiardi, 2013], por esta razón la Inteligencia Artificial (*AI*) (Figura 1.1) ha desarrollado

técnicas o modelos de aprendizaje automático y de reconocimiento de patrones, tales como las Redes Neuronales Artificiales (ANN), lógica difusa [Rotariu, 2013], K-Means, entre otros [FECYT, 2007], que se han utilizado con gran éxito en el área de análisis de imágenes en la medicina y apoyan la toma de decisiones para un diagnóstico más certero.

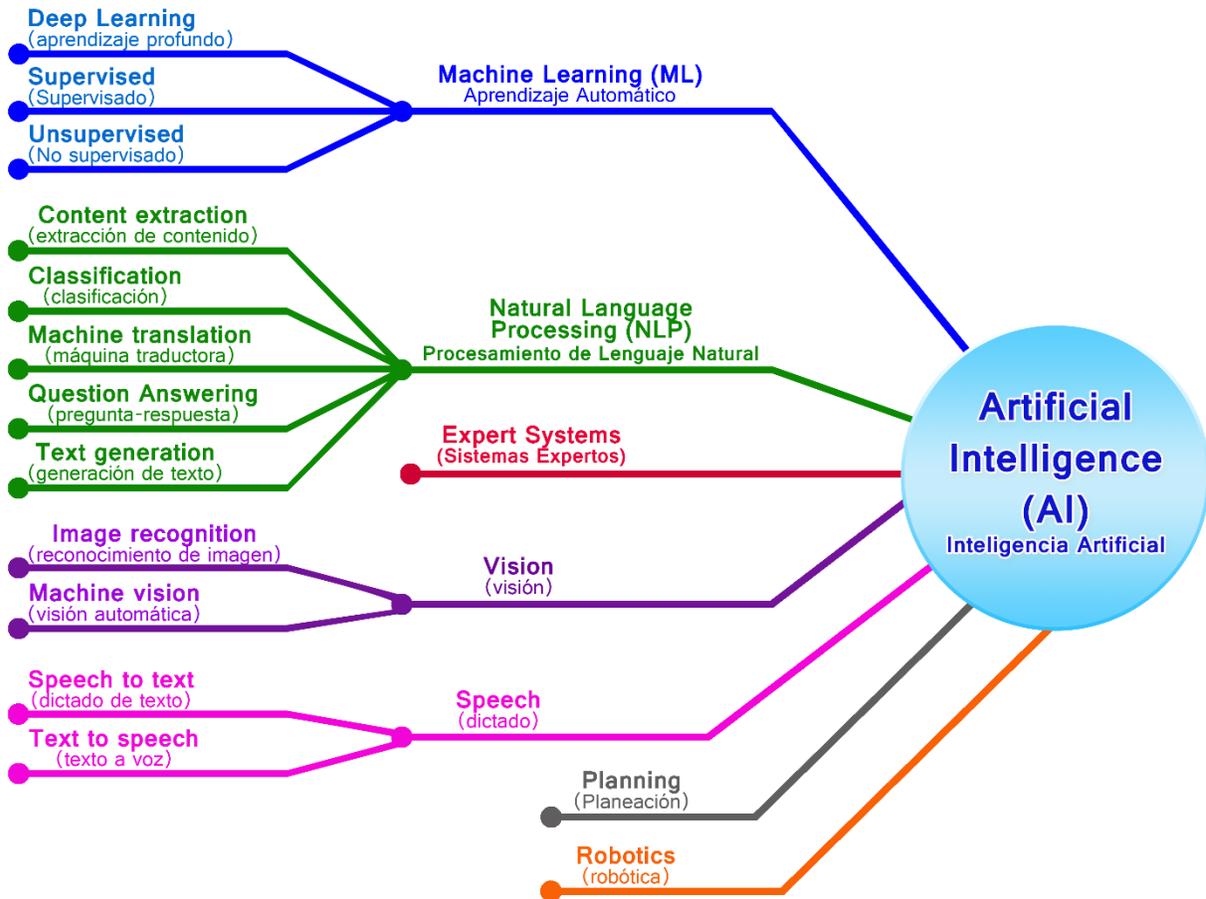


Figura 1.1 Disciplinas que abarca la Inteligencia Artificial [Mills, 2016].

En los últimos años las ANNs de tercera generación como lo son las Redes Neuronales Pulsantes (SNN, por sus siglas en inglés), han generado un gran interés en el tema de reconocimiento de patrones, por el hecho de poseer cualidades cercanas a la realidad biológica de una neurona.

- Las ANNs han ofrecido nuevos enfoques en la resolución de problemas, ofreciendo una alternativa de procedimientos a problemas cuya solución por

técnicas tradicionales resultan de difícil aplicación en la mayoría de los casos, se simulan en máquinas de propósito específico, aceleradores de hardware con arquitectura neuronal e incluso en las computadoras convencionales [Maxinez, 2007]; aunque este esquema es novedoso y muy interesante, en el área de la computación en general, todas las relaciones con el comportamiento inteligente parecen imposibles de alcanzar mediante concepciones computacionales tradicionales [Donachy, 2015].

- Existe una gran cantidad de problemas de ingeniería resueltos con *ANNs*, capaces de emular en mayor o menor medida algunas funciones realizadas por el sistema nervioso de los seres vivos, como la clasificación de patrones, procesamiento de señales, extracción de características, pronóstico de negocios, diagnóstico médico, procesamiento de voz [Matadamas, 2014], control de robots y adaptación de procesos de control [Iakymchuk, 2015], etc.
- Las aplicaciones de sistemas basados en *SNNs*, han permitido diseñar redes con propósitos específicos que, por sus características, permiten realizar el reconocimiento de patrones mediante frecuencias de disparos asociándolos a la tarea de discriminación entre clases, los cuáles pueden representar diversos patrones de disparo que pueden ser utilizados para codificar diferentes tipos de información.

Debido a la importancia del tema, en el presente trabajo de tesis, se aborda el uso de herramientas como las *SNN* en la clasificación de imágenes cerebrales usando el modelo de Izhikevich [Izhikevich, 2003], además de mostrar un panorama amplio de su funcionamiento mediante la experimentación y evaluación de parámetros.

1.2 Descripción del problema

Hoy en día, según la Organización Panamericana de la Salud [OPS, 2014], las *BSD* han ido en aumento, ocupando el segundo lugar a nivel mundial, que debido a su naturaleza y variedad, la atención médica a los pacientes afectados debe ser urgente y especializada.

De todas las causas que provocan una *BSD*, las del tipo isquémico son las más comunes, sin embargo, tienen cierta prevención mediante un diagnóstico oportuno apoyado en el uso de imágenes cerebrales (como tomografías computarizadas, imágenes de resonancia magnética, electroencefalogramas, etc.); éstas imágenes ayudan en la identificación y ubicación de la lesión, obteniendo información sobre la condición y estado estructural del cerebro.

Como se ha demostrado en diversos trabajos, la capacidad en la detección y evaluación de estas lesiones también depende de especialistas que, mediante el tratamiento de dichas imágenes clasifican los cerebros en sanos y no-sanos.

Al analizar este problema, numerosos modelos de *ANNs*, a través de su modelación matemática, han ofrecido una alternativa de diversos procedimientos que ayuden en problemas de clasificación, como lo son las *SNNs* en el área de reconocimiento de patrones.

Por lo que, mediante un conjunto de imágenes cerebrales usadas en el diagnóstico de *BSD*, se requiere que mediante un preprocesamiento, se analicen dichas imágenes por medio de una *ANN* tipo pulsante, la cuál fungirá como clasificadora de cerebros sanos y no-sanos.

1.2.1 Delimitación del problema específico

En la presente tesis se plantea usar imágenes cerebrales monocromáticas, usadas en el diagnóstico de *BSD*, usando técnicas de *AV* en la obtención de sus características, para que mediante un clasificador basado en las *ANNs* de tercera generación como lo son las *SNNs* con modelo Izhikevich, permita describir una imagen cerebral como un cerebro sano o no-sano (Figura 1.2).

1.2.2 Complejidad del problema

El problema de detectar lesiones es un área de investigación abierta, ya que la tarea de dotar a las computadoras de la capacidad de percepción visual para diferenciar imágenes de cerebros sanos y no sanos, por sí sola representa la

posibilidad de conocer más sobre el comportamiento de sistemas inteligentes; conforme se van generando nuevos conocimientos en la forma en que funciona el sistema nervioso surgen nuevos modelos de ANNs, no obstante, entre las técnicas usadas para el reconocimiento de imágenes se encuentran las ANNs de primera y segunda generación.

Aunque en el CENIDET se ha comenzado a experimentar con redes de tercera generación como la Red Neuronal Pulso-Acoplada (PCNM) [Zárate, 2015][Cárdenas, 2015] para la extracción y segmentación de características, así como para la eliminación de ruido gaussiano [Ortiz, 2016], hasta el momento se han analizado algoritmos del aprendizaje de las SNN [Hernández, 2017].

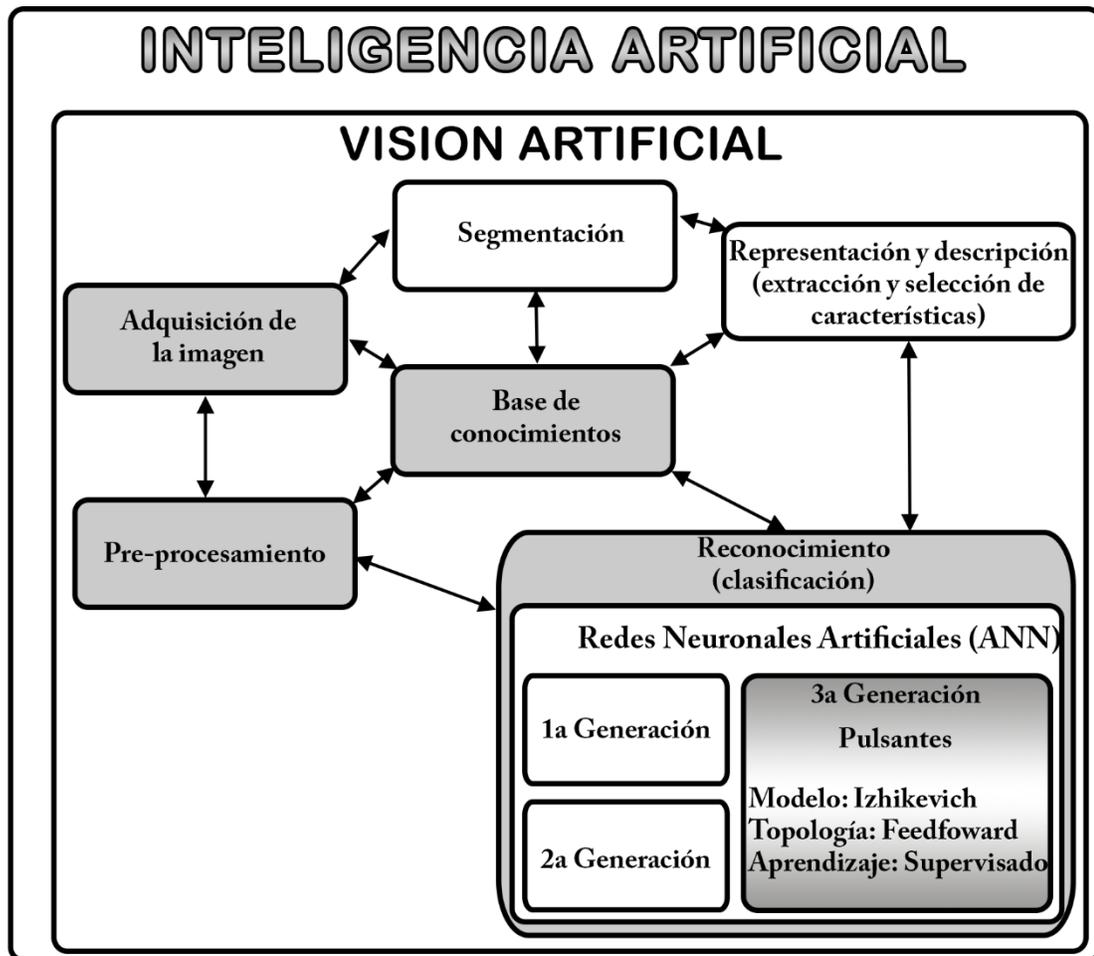


Figura 1.2 Delimitación del problema.

1.2.3 Hipótesis

El uso de las *SNNs* en el área de reconocimiento de imágenes mejora el reconocimiento automatizado de imágenes médicas del cerebro clasificándolas en cerebros sanos y no sanos.

1.3 Objetivos del proyecto de tesis

1.3.1 Objetivo general

Estudiar, analizar e Implementar una *ANN* del tipo Pulsante dentro del dominio de Visión Artificial que mediante el uso de imágenes empleadas en el diagnóstico de enfermedades cerebrovasculares se pueda trabajar en el problema de clasificación.

1.3.2 Objetivos específicos

Los objetivos específicos de este proyecto son:

- Revisar y analizar el área de las *ANNs*, con el fin de estudiar las *SNN*.
- Estudiar algoritmos y/o técnicas para el reconocimiento en imágenes digitales que permitan probar la capacidad de clasificación de las *SNN*.
- Analizar e Implementar una *SNN* aplicada al problema de Visión Artificial, dentro de imágenes médicas del cerebro humano.
- Experimentar con bases de datos de imágenes médicas digitales.
- Conocer las ventajas y desventajas de una *SNN* en el área de reconocimiento de imágenes.

1.4 Alcances y limitaciones

- Analizar diferentes tipos de *ANNs*.
- Revisar y entender al menos 2 problemas típicos de las técnicas de Visión Artificial y de las *ANNs* en el dominio de las imágenes médicas.
- Implementar y analizar una *SNN* aplicada en la interpretación de imágenes médicas del cerebro humano.

- Experimentar al menos con dos bases de datos con imágenes digitales conocidas para la valoración de enfermedades cerebrovasculares.
- Realizar un estudio comparativo contra resultados previos de la literatura.
- Las imágenes utilizadas para la experimentación son de Bases de datos obtenidas de páginas educativas.
- Se utilizarán técnicas y métodos existentes en el estado del arte.
- Las comparaciones se realizarán contra resultados presentados en la literatura o utilizando software o herramientas ya desarrolladas.
- Sólo se busca detectar las ventajas y desventajas de una *SNN* cuando se aplica en el reconocimiento de imágenes

1.5 Justificación y beneficios

La *ANNs* ha representado una herramienta importante dentro de la *AV*, resultando en una técnica muy estudiada en la actualidad, cuyo interés se centra en el gran auge de las *ANNs* pertenecientes a la tercera generación, como lo son las *SNNs*, cuya característica más importante es la capacidad de trabajar mediante series o trenes de pulsos.

Este trabajo de investigación aportará un análisis de las *SNNs* en la clasificación de imágenes, que podrá servir a futuras investigaciones en el área de *AV*, determinando las ventajas y desventajas respecto a otras técnicas de reconocimiento, así como plantear una metodología del modelo de Izhikevich que permita lograr una clasificación en imágenes cerebrales sanas y con anomalías.

Aunque existe una infinidad de padecimientos dentro de las *BSD*, en esta investigación se ha tomado un grupo pequeño de Imágenes de Resonancia Magnética (*MRI*) como ejemplo práctico. El diseño y la experimentación adecuada servirá como punto de apoyo para futuras investigaciones, además de realizar una adecuada clasificación de imágenes con cerebros sanos y no sanos.

1.6 Estructura de la tesis

Este trabajo se enfoca en las Redes Neuronales Artificiales Pulsantes (*SNN*) en el proceso de aprendizaje y capacidad para la detección de lesiones cerebrovasculares en imágenes médicas. Con el fin de situar al lector en el contexto del impacto actual que tiene la *AI* dentro del ámbito médico, la tesis se estructuró de la siguiente manera:



Figura 1.3 Metodología general en la solución del problema de tesis.

En el *Capítulo 2* se presenta una visión general y se detalla el panorama actual del tema estudiado, así mismo se hace un resumen de los antecedentes y literatura encontrada referente al tema de estudio, de modo que sirva para entender por qué se ha planteado este tema como avance en el conocimiento.

El *Capítulo 3*, se incluyen, definen y se describen los conceptos mediante los cuales se plantean las relaciones y categorías que se utilizan en la investigación para mirar el objeto de estudio.

En el *capítulo 4* se plantea la aportación en sí y el núcleo de este trabajo de investigación; en él se describe la metodología o pasos que se siguen en el proceso de reconocer imágenes de cerebros sanos de imágenes con cerebros enfermos, además de mostrar esquemas de la *SNN*.

El *Capítulo 5* expone los resultados de las pruebas de experimentación realizadas en el sistema de reconocimiento basado en *ANNs* con el objetivo de mostrar la aplicabilidad de la investigación.

El *Capítulo 6* ofrece una perspectiva general del resultado del desarrollo de la tesis y sintetiza las conclusiones principales. Se resume la aportación al conocimiento y se incluye una serie de recomendaciones para futuras investigaciones.

Se incluye un CD con un conjunto de *Anexos* de diversa índole; entre otros aspectos incluyen los siguientes:

- ✚ Código de programación de algunas funciones.
- ✚ Modelado de funciones
- ✚ Gráficas y análisis indispensables para la investigación
- ✚ Resultados de las bases de datos

CAPÍTULO 2. MARCO REFERENCIAL

Se describen investigaciones afines al tema, se muestran diversos trabajos de tesis realizados en el CENIDET y una variedad de artículos científicos que hacen énfasis en las *ANNs* de tercera generación. Finalmente se realiza una discusión sobre su uso dentro del estudio de las *BSD*.

2.1 Antecedentes

En la actualidad se desarrolla un creciente interés por el estudio de las *ANNs*, lo que evidencía la importancia que han adquirido en el campo de *AV*. Dentro de las diferentes áreas de investigación del CENIDET, existen varios estudios de maestría que incluyen a las *ANN*, considerándose como una de las herramientas principales en problemas de reconocimiento, clasificación y *AV*; debido a que existen diferentes tipos de *ANN* en la Tabla 2.1 de esta tesis, sólo se describen brevemente los trabajos más recientes dentro del área de Ciencias de la Computación cuyas *ANN* pertenecen a la tercera generación y hacen uso de imágenes en su estudio, sin embargo dichas imágenes no son médicas.

Tabla 2.1 Tesis de Maestría con Redes Artificiales de Tercera generación desarrolladas dentro del Departamento de Ciencias Computacionales del CENIDET.

TÍTULO	OBJETIVO	ANN
Implementación y Evaluación de Redes Neuronales Artificiales tipo " <i>Pulse - Coupled Neural Networks</i> " (<i>PCNN</i>) aplicadas a Visión Artificial [Cárdenas, 2015].	Segmentación de imágenes utilizando <i>PCNN</i> y técnicas tradicionales	Red neuronal pulso-acoplada (primer trabajo de implementación de una <i>PCNN</i> en CENIDET)
Extracción de descriptores de imágenes digitales mediante una red neuronal artificial pulsante [Zárate, 2015].	Obtención de firmas como descriptores de imágenes	<i>SNN</i> y variantes (<i>PCNN</i>)
Detección de ruido impulsivo o Gaussiano en imágenes monocromáticas mediante redes neuronales pulso-acopladas [Ortiz, 2016].	Implementación y evaluación de una <i>ANN</i> tipo pulso-acoplada para problemas de detección de ruido en imágenes digitales	<i>PCNN</i> con matriz de tiempo
Aplicación del descenso de Gradiente para el aprendizaje de neuronas pulsantes de Izhikevich [Hernández, 2017].	Análisis de una <i>ANN</i> tipo pulsante usando modelo de Izhikevich	<i>ANN MLP</i> <i>SNN</i> con modelo Izhikevich

Implementación y Evaluación de Redes Neuronales Artificiales tipo “Pulse - Coupled Neural Networks” (PCNN) aplicadas a Visión Artificial [Cárdenas, 2015]

La investigación presentó el paradigma de la Red Neuronal Pulso-Acoplada (PCNN, por sus siglas en inglés *Pulse-Coupled Neural Network*); y realizó un estudio comparativo de las técnicas tradicionales de AV (como lo es Canny y Sobel) y técnicas que implementan las PCNN para atacar el problema de segmentación en imágenes digitales y detección de bordes. La evaluación de dichos bordes y regiones se validaron mediante la métrica PCM (*Pixel Correspondence Metric*), PixToPix (*Pixel to Pixel*), entropía y entropía cruzada. Posteriormente hizo experimentación mediante una PCNN e ICM (por sus siglas en inglés, *Intersecting Cortical Model*). Sus resultados finales (Figura 2.1 a y b) mostraron que la PCNN y la ICM son comparables en el proceso de segmentación de los bordes con algoritmos tradicionales como lo es Canny, mientras que la PCNN obtiene mejores resultados según la entropía.

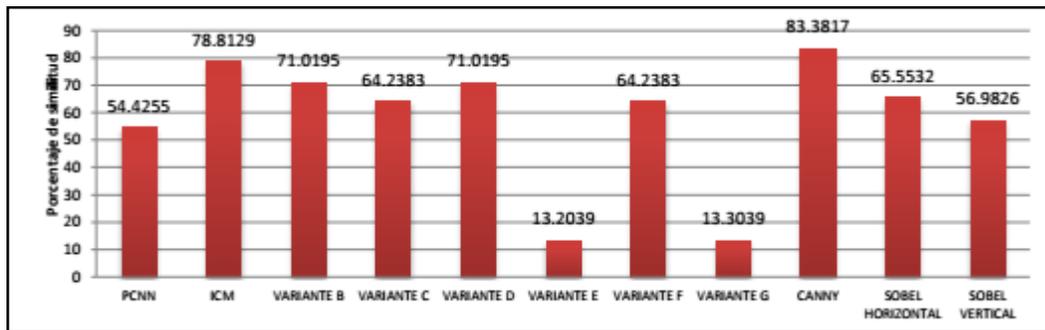


Figura 2.1a Resultados de la evaluación en segmentación de bordes para Lenna [Cárdenas, 2015].

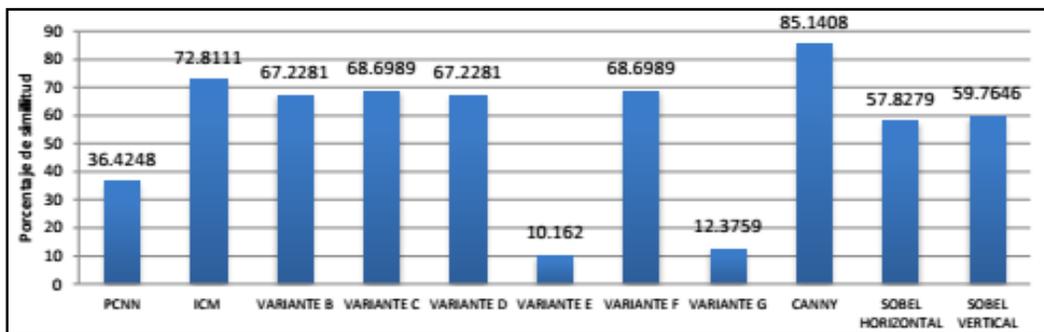


Figura 2.1b Resultados de la evaluación en segmentación de bordes para Cameraman [Cárdenas, 2015].

Extracción de descriptores de imágenes digitales mediante una red neuronal artificial pulsante [Zárate, 2015].

Este trabajo utilizó la *PCNN* para la extracción de descriptores de imágenes digitales con el fin de crear firmas a partir de ella, además de usar metodologías como la entropía cruzada y *PCM*. También procesó imágenes mediante paradigmas *ICM* y *SCM*.

En la Tabla 2.2 se muestran los resultados de la comparación de las *SNNs* contra otros métodos de extracción de características de las imágenes, con la medida de similitud de comparación entre “Firmas” de una imagen.

Tabla 2.2 Resultados de la comparación de similitud con diferentes paradigmas pulsantes [Zárate, 2015].

Paradigma	Otras carac				Otras carac				PCNN		Otras carac	
	PCNN	ICM	SCM	PCNN	ICM	SCM	PCNN	ICM	PCNN	ICM	PCNN	ICM
Tipo de imagen 1	Mont	Mont	Mont	Mont	Pasto	Pasto	Pasto	Pasto	Flores	Flores	Flores	Flores
Tipo de imagen 2	Flores	Flores	Flores	Flores	Mont	Mont	Mont	Mont	Pasto	Pasto	Pasto	Pasto
Serie tiempo	99.53	94.08	92.01	70.58	99.74	96.14	96.70	80.88	99.72	95.75	95.05	81.46
Energía de tiempo	99.35	79.92	77.79	49.48	99.58	87.18	89.03	64.88	99.65	84.83	85.86	66.41
Media Residual	94.89	59.58	92.01	51.43	97.04	75.82	96.70	69.51	97.11	70.30	95.05	67.77
Desviación Estándar	94.76	67.07	77.10	43.98	97.35	76.63	88.72	59.27	96.78	73.96	85.45	61.89
Entropía	84.05	98.03	91.18	81.24	88.73	98.59	95.52	87.88	89.46	98.53	94.85	88.45
Energía logarítmica	84.92	94.35	82.88	80.71	88.62	95.26	89.61	85.65	89.07	96.22	90.55	88.45
Logarítmica	69.25	64.54	69.52	81.91	73.63	72.29	68.10	86.64	72.37	78.21	67.68	89.89
Energía Entrópica	69.25	64.54	69.52	81.91	73.63	72.29	68.10	86.64	72.37	78.21	67.68	89.89
Energía ponderada	98.90	88.08	92.01	67.41	99.40	92.79	96.70	79.83	99.35	91.36	95.05	79.77

En cada cuarta columna se observa que el paradigma *SCM* mantiene una mejor separabilidad entre tipo de imágenes distintas, es decir más cercano a 0.

El paradigma *PCNN* tiene un mejor comportamiento para extraer descripciones de imágenes digitales, ya que genera con mayor facilidad firmas diferentes para imágenes distintas.

Detección de ruido impulsivo o Gaussiano en imágenes monocromáticas mediante redes neuronales pulso-acopladas [Ortiz, 2016]

Se encontraron parámetros de los algoritmos de detección de ruido impulsivo y gaussiano basados en una *PCNN* que generaron los mejores resultados en remoción

de ruido y conservación de detalles al probarse con imágenes digitales estándar monocromáticas.

Como resultado, la Tabla 2.3 ilustra el hecho de que la *PCNN* original fue descartada para el filtrado de ruido impulsivo ya que sólo detecta el 50% del ruido. Las variantes *ICM* y *SCM* recuperan mejor la imagen para varianzas de ruido gaussiano menores a 0.02.

Tabla 2.3 Resumen de características de filtrado de ruido impulsivo con *PCNN* y filtros tradicionales. [Ortiz, 2016]

Filtro	Rango de filtrado efectivo (probabilidad)	Máxima capacidad de restauración de la imagen <i>PSNR</i> (dB)	Capacidad de preservación de detalles finos <i>MAE</i>	Invariancia a la escala	Invariancia a la rotación	Tiempo de procesamiento (ms)
Mediano de 3x3	0 - 0.3	20	5	Media	Alta	40
Promedio de 3x3	0.1 – 0.3	10	20	Alta	Alta	10
Morfológico de 3x3	0 – 0.3	15	10	No determinado	No determinado	300
<i>ICM</i>	0 – 0.5	30	3	Baja	Alta	20000
<i>SCM</i>	0 – 0.5	25	4	Baja	Alta	225

Por lo que, como resultado, las *PCNN* tienen potencial en la detección de los píxeles ruidosos o bien para proporcionar información temporal sobre la activación de los píxeles ruidosos, como se constató para el caso del ruido gaussiano (Tabla 2.4).

Tabla 2.4 Características de filtrado de ruido gaussiano con *PCNN* y filtros tradicionales [Ortiz, 2016].

Filtrado de ruido impulsivo	Rango de filtrado efectivo (varianza)	Capacidad de restauración de la imagen <i>PSNR</i> (dB)	Capacidad de preservación de bordes <i>MAE</i>	Tiempo de procesamiento (s)
Filtro Wiener de 5x5	0.02 – 0.09	10	20	0.06
Filtro de mediana de 3x3	0.02 – 0.06	9	21	0.03
<i>ICM</i>	0.01 – 0.02	8	35	112
<i>SCM</i>	0.01 – 0.03	5	30	0.5
<i>PCNNNI</i>	0.02 – 0.06	2	30	1.8

Aplicación del Descenso de Gradiente para el aprendizaje de neuronas pulsantes de Izhikevich [Hernández, 2017]

Este trabajo aporta por primera vez la comprensión matemática del modelo neuronal Izhikevich dentro del CENIDET, generando un análisis del algoritmo de aprendizaje con descenso del error de forma similar que en una red multicapa.

Se abordó la resolución y comparación del comportamiento de la neurona Izhikevich sobre bases de datos conocidas (Lógicas, *Ionosphere*, *Breast Cancer*, *Iris Data Set*, entre otras), cuyos resultados se sintetizan en la Tabla 2.5.

Tabla 2.5 Comparativa de las bases de datos académicas [Hernández, 2017].

Base de datos	Patrones	Atributos	Clases	Épocas	Entrenamiento	Validación
<i>AND</i>	4	2	2	2	100%	Sólo se entrena
<i>OR</i>	4	2	2	8	100%	Sólo se entrena
<i>XOR</i>	4	2	2	8	100%	Sólo se entrena
Pagan y no pagan	30	2	2	18	86.66%	Sólo se entrena
<i>Ionosphere</i>	351	35	2	33	89.57%	87.14%
<i>W.Breast Cancer</i>	683	10	2	157	94.14%	95.97%
<i>Iris</i>	150	4	3	8	91.11%	88.33%
Imág. Cerebros	111	7	2	1,483	85.07%	84.09%

Se observa (Tabla 2.5) que se obtuvieron datos favorables, donde todos los porcentajes están por encima de 84%. Como conclusión se documenta el uso de un algoritmo de computación evolutiva como método de aprendizaje para el modelo neuronal, así como un esquema de funcionamiento del entrenamiento de retro propagación del error en una red neuronal multicapa.

Algo importante de la experimentación fue la parte de clasificación, en un principio se desea que la neurona arroje una cantidad de pulsos deseada, sin embargo, tal y como en los modelos de primera y segunda generación, la clasificación después del entrenamiento difícilmente resulta ser exacta, debido a que la cantidad de pulsos queda muy cerca del valor deseado.

Se realizó el estudio del aprendizaje para una sola neurona con modelo Izhikevich, generando un análisis del descenso del error de forma similar que en una red multicapa.

2.2 Estado del Arte

La importancia de este tema de tesis radica en la correlación entre las técnicas usadas en la obtención de imágenes cerebrales y las técnicas de AV como lo son las ANNs, por lo tanto, a continuación, se presentan estudios que ayudaron en este tema de tesis. La literatura consultada (Tabla 2.6) corresponde a 32 artículos, de donde se analizaron algunos conceptos, procedimientos de experimentos, bases de datos, etc.

Tabla 2.6 Información relevante de técnicas de trabajos revisados.

Artículo	Aportes a la investigación	Fuentes de imágenes cerebrales o Bases de Datos	Técnicas empleadas	Tipo de ANN empleada
Networks of Spiking Neurons: the 3rd generation of Neural Networks Models [Maass, 1997]	Representación de arquitecturas de ANNs con elementos biológicos como lo son los potenciales de acción y la umbralización de pulsos.	Ninguna	✓ Ejemplificación de tres teoremas acerca del comportamiento de las SNN así como elementos que la componen.	SNN
Introduction to SNN: information processing, learning and applications [Ponulak, 2011]	Se resumen las propiedades básicas de las neuronas y redes pulsantes, como los modelos de codificación de información basada en pulsos, plasticidad sináptica y aprendizaje.	En general	✓ ANN	SNN
Classification of MRI Brain Images Using Neural Network [Bhaiya, 2012]	Ayudar al médico en la toma de decisiones en el diagnóstico de un cerebro sano y patológico, mediante el uso de diferentes técnicas y otros métodos de aprendizaje supervisado.	MRI	✓ Algoritmo de BP con LVQ ✓ Matriz de covarianza ✓ PCA ✓ Transformada de Wavelet	MLP con métodos de aprendizaje BP, RBF y LVQ.
Classification of Normal and Epileptic EEG Signal using Time & Frequency Domain Features through ANN. [Anusha, 2012]	Clasificar con una ANN <i>Feedforward</i> el análisis realizado por un EEG para la detección de epilepsia.	EEG	✓ ANN MLP ✓ Ventana Deslizante	MLP

Tabla 2.6 Información relevante de técnicas de trabajos revisados. (continuación)

Artículo	Aportes a la investigación	Fuentes de imágenes cerebrales o Bases de Datos	✓ Técnicas empleadas	Tipo de ANN empleada
Image processing with SNN [Boudjelal, 2012]	Aplicación de un modelo de SNN para la agrupación de imágenes, segmentación y detección de bordes, y su selección de parámetros.	-Berkeley (50 imágenes) -Base de datos pública de ocho imágenes microscópicas de tumores bronquiales de 752 x 574 pixeles).	✓ SOM ✓ <i>K-means</i> ✓ Diversos métodos de evaluación como: -PSNR -MSE -MAE - NCD ✓ Matriz de confusión	SOM SNN
Image Segmentation using Leaky Integrate and Fire Model of SNN [Chaturvedi, 2012]	Simulación de una SNN con algoritmo LIF, donde después de realizar una selección y extracción de las características de una imagen correspondientes a una clase, que son manejadas como vectores, para ser analizados con la red.	En general	✓ ANN ✓ Algoritmo IF ✓ Algoritmo LIF ✓ <i>K-means</i>	SNN con: ▪ IF ▪ LIF
A survey on pattern recognition using SNN with temporal encoding and learning [Dhilipan, 2014]	Mostrar un panorama del uso de las SNN en la identificación de patrones, así como diferentes reglas de entrenamiento usadas por estas redes.	Sólo mención de resultados: - Iris - MINST - <i>Spatio Temporal Data</i> - Vidtimt - Benchmark	✓ STDP ✓ Regla de aprendizaje hebbiana ✓ Adaptación estructural y operación cuadro por cuadro (<i>frame by frame</i>). ✓ <i>Spike Prop</i> con error de propagación.	SNN con STDP
An online supervised learning method for SNN with adaptive structure [Wang, 2014]	Presenta un método de aprendizaje híbrido en una SNN cuya característica importante es la capacidad de clasificar entradas mediante STDP.	<i>Wisconsin breast cancer</i>	✓ SNN	SNN con RBF.
Computing with SNN: a review [Ahmed, 2014]	Describir el funcionamiento de las ANNs de 3ª generación mediante el estudio de la arquitectura y de los disparos de pulsos generados por SNNs.	Ninguna	✓ SNN	SNN en general

Tabla 2.6 Información relevante de técnicas de trabajos revisados. (continuación)

Artículo	Aportes a la investigación	Fuentes de imágenes cerebrales o Bases de Datos	Técnicas empleadas	Tipo de ANN empleada
Aplicación de las SNNs en el reconocimiento de patrones y análisis de imágenes [Matadamas, 2014]	Entrenamiento de una SNN mediante un algoritmo de evolución diferencial.	-Problema XOR -Reconocimiento de voz - Iris -Wine -Vidrio -Desórdenes del Hígado -Umbralado de imágenes	✓ SNN con modelo Izhikevich. ✓ Algoritmo de evolución diferencial. ✓ Matriz de co-ocurrencia. ✓ Umbralización	SNN con modelo Izhikevich.
Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm [El-Dahshan, 2014]	Revisión general de las técnicas de segmentación y clasificación más comúnmente utilizadas en las imágenes cerebrales normales y anormales.de MRI en sistemas CAD.	- 101 MRI con tumores cerebrales (14 normales y 87 anormales).	✓ FPCNN ✓ Transformada de Wavelet Discreta. ✓ PCA ✓ Coeficientes Wavelet ✓ FFBPNN	FPCNN PCNN SOM FFBPNN
Detection of Tumor in MRI Images Using Artificial Neural Networks [Aqhsa, 2014]	Clasificar automáticamente los tejidos del cerebro en normales y anormales mediante diferentes técnicas en la obtención de características para alimentar una red MLP.	MRI	✓ ANN ✓ Operaciones morfológicas ✓ Descriptores de textura Haralick ✓ Umbralización	MLP
Izhikevich Model Based Pattern Classifier For Hand Written Character Recognition- A Review Analysis [Chaturvedi, 2014]	Se comprueba la eficacia computacional de la neurona Izhikevich con respecto a la LIF(Leaky Integrate and Fire).	Ninguna	✓ SNN con modelado de Izhikevich ✓ SNN con modelado LIF	Modelo Izhikevich Modelo LIF
Classification Of Persian Hand-written Digits Using SNN [Kiani, 2015]	Se evalúan imágenes con ruido construidas con píxeles binarios usando una RBM para extraer las características y correlación entre los píxeles de dígitos escritos y clasificarlos.	Dígitos persas escritos a mano (Hoda Persian)	✓ RBM ✓ SNN con STDP ✓ SNN tipo DBN	SNN con RBM DBN

Tabla 2.6 Información relevante de técnicas de trabajos revisados. (continuación)

Artículo	Aportes a la investigación	Fuentes de imágenes cerebrales o Bases de Datos	Técnicas empleadas	Tipo de ANN empleada
A minimal SNN to rapidly train and classify handwritten digits in binary and 10- digit tasks [Maida, 2015]	Evaluación de una <i>SNN</i> compuestas por neuronas de picos regulares de Izhikevich. Los resultados de la simulación muestran que la <i>SNN</i> propuesta se entrena rápidamente sin retroalimentación de errores en un número reducido de iteraciones, en comparación con otras técnicas como la SVM.	En general Imágenes con manuscritos de dígitos	<ul style="list-style-type: none"> ✓ ANN ✓ Algoritmo Izhikevich ✓ SVM ✓ <i>SNN</i> con modelo Izhikevich 	<i>SNN</i> con Izhikevich MLP
ASIC implementation for improved character recognition and classification using SNN model [Chaturvedi, 2015]	Demostrar la eficiencia de clasificación de una <i>SNN</i> basada en simulaciones de Matlab con regla de aprendizaje <i>LIF</i> , la atención se centra en el consumo de energía y el costo del sistema, además describe al modelo <i>SNN</i> de Izhikevich como el más adecuado para simulaciones corticales a gran escala debido a su precisión, eficiencia, potencia y tiempo de simulación.	27 Caracteres del alfabeto en inglés	<ul style="list-style-type: none"> ✓ <i>SNN</i> con modelo Izhikevich ✓ Filtro Gaussiano ✓ Algoritmo <i>Canny</i> ✓ Filtro Gabor ✓ <i>SNN</i> con <i>LIF</i> 	<i>SNN</i> con modelo Izhikevich <i>SNN</i> con <i>LIF</i>
Pattern recognition with SNN: a simple training method [Francois, 2015]	Entrenar una <i>SNN</i> para el reconocimiento de patrones basado en la <i>STDP</i> de las conexiones.	En general	<ul style="list-style-type: none"> ✓ Plasticidad dependiendo el tiempo de pulsos (<i>STDP</i>) ✓ ANN 	<i>SNN</i>
Simplified SNN architecture and STDP learning algorithm applied to image classification [Iakymchuk, 2015]	Simulación de una <i>SRM</i> con <i>IF</i> , que ayuda a clasificar imágenes en blanco y negro con ruido.	Semeion	<ul style="list-style-type: none"> ✓ <i>SRM</i> con <i>IF</i> ✓ <i>SNN</i> con <i>STDP</i> Análisis del <i>PSP</i> 	<i>SRM</i> con <i>IF</i>

Tabla 2.6 Información relevante de técnicas de trabajos revisados. (continuación)

Artículo	Aportes a la investigación	Fuentes de imágenes cerebrales o Bases de Datos	Técnicas empleadas	Tipo de ANN empleada
Spiking Neural Networks for vision task [Martin, 2015]	Descripción del funcionamiento de las SNN, comparación con las redes convolucionales y ejemplos.	Símbolos de póker, MNIST, CIFAR-10, AER Posture Dataset	✓ CNN ✓ SNN	SNN
A survey of randomized algorithms for training neural networks [Zhang, 2016]	Presenta métodos basados en la aleatorización para el aprendizaje de las SNN basados en la optimización de redes neuronales.	Ninguna	✓ Aprendizaje evolutivo y RBF ✓ Perceptron y ANN Feedforward con parámetros aleatorios	No explícita
Automatic stroke lesion segmentation from diffusion weighted MRI [Karthikeyan, 2016]	Detección de lesiones grandes y pequeñas aplicando técnicas de filtrado, crecimiento de regiones y un algoritmo de disoluciones.	MRI	✓ Operaciones Morfológicas ✓ Filtro mediano ✓ Crecimiento de Regiones ✓ Algoritmo de disoluciones	ANN probabilística.
Clasificación de patrones mediante el uso de una SNN [Hernández-Becerra, 2016]	Mostrar el alcance que tienen las neuronas pulsantes dentro de la clasificación, en la resolución de problemas no lineales, haciendo una descripción matemática usando el modelo Izhikevich.	XOR lonosphere	✓ MLP ✓ Algoritmo de evolución diferencial ✓ Modelo Izhikevich	MLP SNN con aprendizaje de algoritmo de evolución diferencial usando el modelo Izhikevich.
Classification of Human Brain Signal for Diagnosis of Stroke Disease Using ANN [Igwe, 2016]	Utilizar el modelo ANN para clasificar el informe de la señal de un EEG generado por el cerebro para el diagnóstico de accidente cerebrovascular.	EEG	✓ Filtrado	MLP
Effect of image enhancement on MRI brain images with neural networks [Dimililer, 2016]	Desarrollar un algoritmo de procesamiento de imágenes para la detección de cáncer de cerebro en imágenes de MRI.	MRI	✓ Operaciones morfológicas ✓ Filtro mediano ✓ ANN	Retropropagación con error

Tabla 2.6 Información relevante de técnicas de trabajos revisados. (continuación)

Problemática	Fuentes de imágenes cerebrales o Bases de Datos	Técnicas empleadas	Tipo de ANN empleada
Histogram-Based Texture Characterization and Classification of Bra-in Tissues in Non-Contrast CT Images of Stroke Patients [Agwu, 2016]	CT	<ul style="list-style-type: none"> ✓ Histograma en ROIs seleccionados ✓ Software MaZda 	MLP

2.3 Discusión del estado del arte

De este análisis, se puede concluir que aunque todavía se sigue clasificando con ANN de primera generación (como lo son las *Multi-Layer Perceptron* citadas en [Hernández, 2017], [Aqhsa, 2014], [Anusha, 2012], [Kupershtein, 2016] [Gupta, 2015] [Hernández-Becerra, 2016] y [Agwu, 2016]), existe un gran interés en utilizar ANNs de tercera generación en el procesamiento de imágenes [Boudjelal, 2012], que a pesar de contar con modelos sustentados en el comportamiento biológico (como lo son las *PCNN* [Johnson, 1999] [Cárdenas, 2014]), actualmente diversos autores han propuesto diferentes arquitecturas de *SNN*. Así mismo hacen énfasis en su función biológica [Maass, 1997] como la generación de pulsos [Ponulak, 2011] y potenciales de acción [Ahmed, 2014] que realiza una neurona, así como la variación en el tiempo en que éstos pulsos ocurren (plasticidad sináptica) [Ponulak, 2011] [Wang, 2014], y algunos mecanismos de aprendizaje que realizan [Yu, 2014] [Diehl, 2014] [Zhang, 2016].

Aunque algunas de estas arquitecturas han llegado a ser muy eficientes, la complejidad de las *SNN* sigue radicando en la calidad de la muestra de patrones atípicos para su entrenamiento (datos diferentes al resto de los patrones de la misma clase) [Dhilipan, 2014], [François, 2015], [Chaturvedi, 2014], [Chaturvedi, 2015], [Igwe,

2016], también el que exista un desbalance entre los datos (que pertenezcan a una clase más pequeña respecto a otra) lo que hace disminuir la precisión del clasificador [Matadamas, 2014], [Hernández-Becerra, 2016].

Sin embargo, las *SNN* representan una tecnología computacional capaz de solucionar problemas de aprendizaje o *AV* (por ejemplo, en el reconocimiento de patrones o segmentación de imágenes [Chaturvedi, 2012]).

Demostrando que las *SNN* son capaces de descubrir automáticamente relaciones, entrada-salida (o rasgos característicos) en función de datos empíricos, merced a su capacidad de aprendizaje a base de ejemplos, esto permite resolver problemas que ayudan a una mejor toma de decisiones como se demuestra en [Bhaiya, 2012], [Anusha, 2012], [El-Dahshan, 2014], [Aqhsa, 2014], [Kiani, 2015], [Gupta, 2015] y [Iakymchuk, 2015].

Esta capacidad para deducir un significado de datos complicados o imprecisos [Suryawanshi, 2015] [Karthikeyan, 2016], pueden ser utilizadas para detectar patrones o detectar una tendencia que es muy compleja de hallar [Dimililer, 2016] [Agwu, 2016] como por ejemplo en las imágenes cerebrales de resonancia magnética.

Como se estudió, la dinámica de la neurona biológica está determinada por las sustancias producidas en la sinapsis con información genética de la propia neurona, en diversos trabajos se ha representado de diferente manera, como por ejemplo la investigación de Hodgkin-Huxley que aunque tiene cuatro ecuaciones, generan decenas de parámetros y millares de operaciones de coma flotante para un milisegundo de simulación, también hay modelos sencillos como el de [Izhikevich, 2004] donde plantea su modelo como el más adecuado, ya que consta con dos ecuaciones y cuatro parámetros, que simulan diferentes tipos de neuronas y es rápido (13 FLOPS), y han dado resultados favorables como en [Maida, 2015], [Chaturvedi, 2014] y [Chaturvedi, 2015].

Las tesis analizadas anteriormente realizadas en el CENIDET, estudian el problema de reconocimiento de patrones de una imagen, como es el caso de [Cárdenas, 2015] cuya importancia radica en el análisis de una *ANN* tipo *PCNN*, evaluando sus ventajas y desventajas en la segmentación de imágenes con respecto

a técnicas tradicionales; [Zárate, 2015] usa el mismo tipo de red ampliando el tema con el estudio de diversas variaciones de la *PCNN*, con el fin de analizar el problema de extracción de descriptores o características de imágenes digitales, de igual manera [Ortiz, 2016] ocupa la *PCNN* en el problema de detección de ruido impulsivo o gaussiano, por lo que estos estudios muestran que se pueden imitar dichos métodos para obtener diversas características de una imagen que ayuden en el reconocimiento de *BSD*. La investigación de [Hernández, 2017] fue diseñada para indagar y analizar el aprendizaje de las *SNN* usando el modelo Izhikevich, siendo este trabajo una perspectiva del funcionamiento de este modelo.

Para este trabajo de tesis, las investigaciones de [Chaturvedi, 2012] y [Aqhsa, 2014], marcaron la pauta en la selección y extracción de características que realizaban a las imágenes, para alimentar a las *ANNs*.

De igual manera, [Matadamas, 2014] desglosa un sin número de ejemplos usando el modelo Izhikevich, en el reconocimiento de patrones mediante un algoritmo de evolución diferencial, así como la explicación detallada del funcionamiento de una *SNN*. Por último, la investigación de [Hernández, 2017] describe un análisis del entrenamiento de *SNNs*, por medio de una aplicación del descenso de gradiente usando el modelo Izhikevich.

CAPÍTULO 3. MARCO TEÓRICO - CONCEPTUAL

Se definen conceptos básicos que coadyuvarán a tener una mejor comprensión de la terminología de este proyecto, se describe la investigación de los elementos básicos estudiados en este tema de tesis, iniciando con una definición de *BSD*, algunas técnicas en la obtención de imágenes cerebrales, acercamiento a las *ANNs* enfocándose en las *SNNs*, seguido de su clasificación, topología y tipo de aprendizaje.

3.1 Enfermedades Cerebrovasculares

Según la Organización Panamericana de la Salud [OPS, 2014], las Enfermedades Cerebro-Vasculares (*BSD*, por sus siglas en inglés) se encuentran dentro de las diez principales causas de muerte a nivel mundial, siendo este tipo de padecimientos la causa principal de incapacidad en adultos.

Las *BSD*, también llamadas *ictus*, se definen como un conjunto de enfermedades que ocurren cuando hay afectaciones en los vasos sanguíneos del cerebro, que provoca la disminución repentina de flujo sanguíneo o el rompimiento de ellos [Chyzyk, 2015], ocasionando que las células cerebrales vecinas mueran por falta de oxígeno, causando secuelas que pueden variar en su magnitud, desde leves hasta severas (como problemas de raciocinio y coordinación motora, parálisis, dificultad del habla y visión) e incluso la muerte [Menaka, 2015].

Las *BSD* se clasifican dentro de dos grandes grupos según su naturaleza, y se agrupan en isquémicos y hemorrágicos [Blanco, 2011].

Aunque existen diversas *BSD*, el alcance del presente trabajo de tesis se limita a reconocer imágenes de cerebros que han sido diagnosticados como sanos o como enfermos, sin especificar el tipo de enfermedad.

3.1.1 Hemorrágica

[Menaka, 2015] mencionan que las *BSD* hemorrágicas se deben a un espacio débil en la pared de un vaso sanguíneo, es decir existe un sangrado anormal que interrumpe el flujo sanguíneo regular (Figura 3.1), generalmente este tipo de *BSD* son las menos

comunes, sin embargo, son difíciles de detectar a tiempo, ya que en cuestión de segundos o minutos las células del cerebro comienzan a morir.

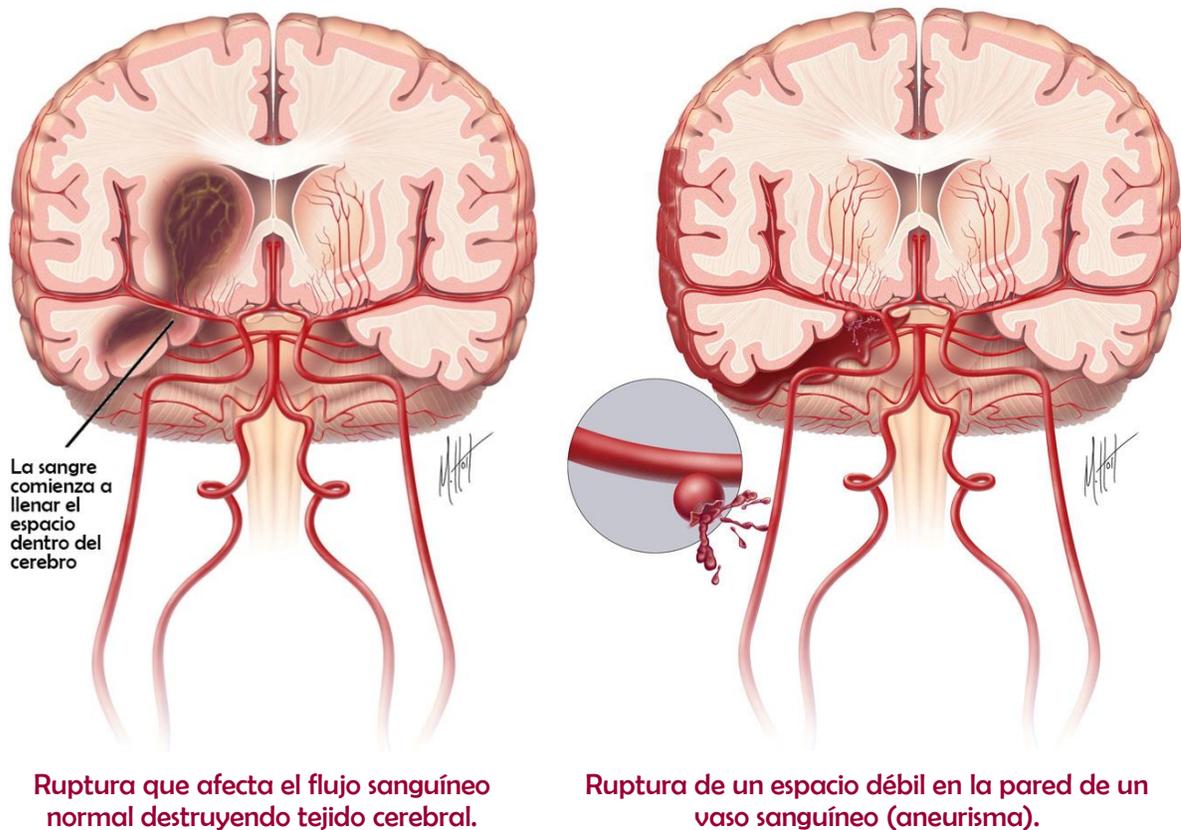


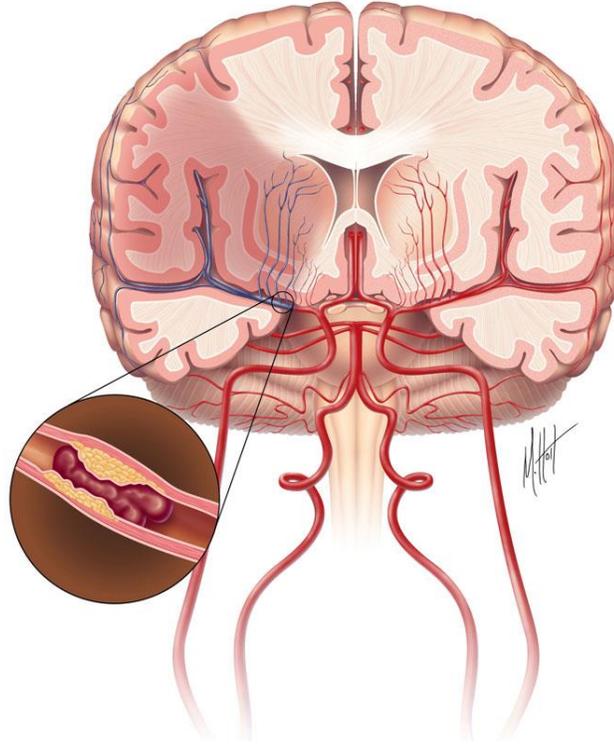
Figura 3.1 Representación de una enfermedad cerebro-vascular hemorrágica [StrokeCenter, 2018a]

3.1.2 Isquémica

[Jalilvand, 2011] describe que en este tipo de accidente una arteria del cerebro se encoge o se bloquea completamente impidiendo el flujo sanguíneo regular (Figura 3.2), esto se produce a causa de:

- Un coágulo de sangre que se forma en una arteria poco saludable del cerebro, también llamado trombo.
- O por un émbolo, que es un coágulo que se forma en otra parte del cuerpo y viaja hasta el cerebro [Menaka, 2015].

Las BSD isquémicas son las más frecuentes y algunas pueden prevenirse [Menaka, 2015].



Trombosis causada por la obstrucción en una vena.

Figura 3.2 Representación de una enfermedad cerebro-vascular isquémico [StrokeCenter, 2018b]

Las BSD pueden diagnosticarse mediante el uso de imágenes médicas obtenidas por medio de tomografías computarizadas, ultrasonidos (como el doppler), imágenes de resonancia magnética, electroencefalogramas, etc. [Blanco, 2011], dichas imágenes son invaluable, debido a que se tratan de métodos no invasivos en la detección de estos padecimientos [Rihiardi, 2013].

3.2 Técnicas para el diagnóstico de enfermedades cerebrovasculares

En [García, 2010] imagen médica es definida como *“aquella que resulta del conjunto de técnicas y procesos usados para crear imágenes del cuerpo humano, o partes de él, con propósitos clínicos, es decir imágenes que buscan revelar,*

diagnosticar o examinar enfermedades, o bien imágenes usadas en propósitos científicos médicos”.

El diagnóstico por interpretación de imágenes es invaluable, ya que se trata de un método no invasivo para la detección de enfermedades. El reconocimiento de imágenes médicas de forma automatizada reduce el tiempo en la evaluación y minimiza errores en el diagnóstico y tratamiento de enfermedades [Rihiardi, 2013], por lo tanto, esta actividad forma parte importante en el análisis de una *BSD*.

En este trabajo se definen cuatro técnicas en la obtención de imágenes cerebrales, así como las características de cada una de ellas.

3.2.1 Electroencefalograma (*EEG*)

Capta la actividad eléctrica del cerebro durante un período de tiempo [Igwe, 2016], suministrando información sobre la función cerebral, es decir, las células del cerebro se comunican entre sí produciendo pequeñas señales eléctricas llamadas impulsos (Figura 3.3), las cuáles se registran a partir de electrodos colocados en el cuero cabelludo para obtener múltiples canales, la señal eléctrica recogida se amplifica y se representa en forma de líneas a lo largo del tiempo [Ceballos, 2010]. Aunque esta técnica no produce imágenes en el sentido estricto del término, producen mapas de datos que pueden ser vistos como pseudo-imágenes médicas [García, 2010].

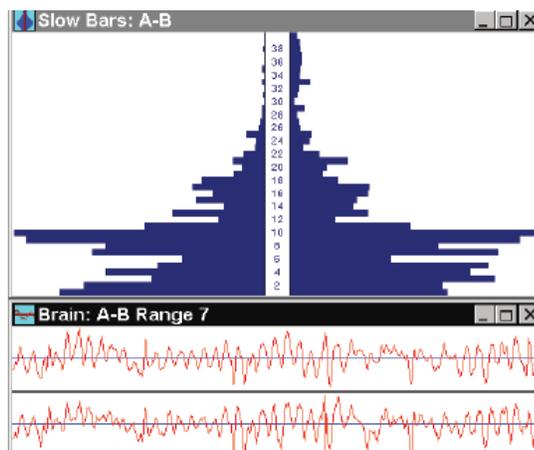


Figura 3.3 Señal de ondas cerebrales con EGG [Monge-Pereira, 2014].

3.2.2 Ultrasonido Doppler (UD)

Es una herramienta que ayuda a visualizar el funcionamiento de los vasos cerebrales, evaluando tanto la dirección como la velocidad del flujo sanguíneo a través de las arterias más importantes del cerebro (Figura 3.4); aplicando esta técnica en la evaluación de una *BSD*, resulta una herramienta importante en el estudio del flujo sanguíneo además de determinar el grosor de las paredes de las arterias carótidas [Alet, 2015].

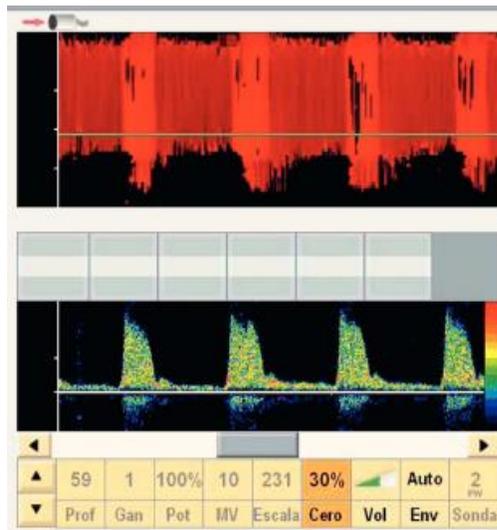


Figura 3.4 Arteria cerebral media con alta presión intracraneal captada por ultrasonido Doppler [Matamoros, 2009].

3.2.3 Tomografía computarizada (CT)

Es una técnica realizada mediante la aplicación de Rayos X, que obtiene múltiples imágenes detalladas en distintos ángulos (Figura 3.5 a y b), lo cual permite diversas vistas del cerebro; puede diferenciar con gran precisión una *BSD* isquémica de una hemorrágica [Blanco, 2011].

3.2.4 Imagen de Resonancia magnética (MRI)

Se realiza dentro de un campo magnético que, junto con la radio frecuencia, altera el alineamiento natural de los átomos de hidrógeno en el cuerpo [Pukish, 2013], es decir, se basa en una tecnología sofisticada que estimula y detecta el cambio en la

dirección del eje de rotación de protones que se encuentran en el agua que componen los tejidos vivos, originando imágenes anatómicas detalladas, sin el uso de la radiación dañina (Figura 3.5 c).

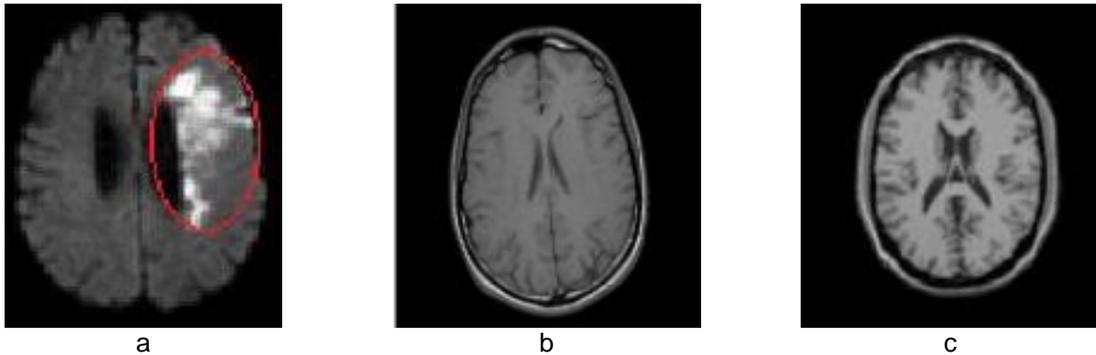


Figura 3.5 Imágenes Cerebrales: (a) CT anormal, (b) CT normal, (c) MRI normal [DespotoviT, 2015].

Algunas ventajas y desventajas de cada una de las técnicas anteriormente descritas se describen en la Tabla 3.1.

Tabla 3.1. Ventajas y desventajas de las técnicas de interpretación de imágenes cerebrales.

TÉCNICA	VENTAJAS	DESVENTAJAS
EEG	<ul style="list-style-type: none"> ✓ Diagnosticar y monitorear una <i>BSD</i> específicas, como lo son el Alzheimer o la epilepsia [Martínez-Vila, 2011]. ✓ No es invasivo ya que mide la actividad eléctrica desde el exterior del cerebro, generando una traza de datos sin utilizar radiaciones y sin energía magnética. ✓ Cuando se diagnostica una <i>BSD</i> del tipo isquémico, es muy sensible ya que se observan diversos cambios anormales en los patrones debido al bajo nivel de oxígeno que presenta el cerebro [Abdulrahman, 2015]. ✓ Es muy útil en la rehabilitación del paciente que sufrió una <i>BSD</i> [Guo, 2009] 	<ul style="list-style-type: none"> ✓ Requiere de profesionales capacitados para su interpretación por lo que puede resultar tediosa y requiere tiempo [Martínez-Vila, 2011]. ✓ Generalmente es usada para rectificar enfermedades específicas del tipo cognitivo como la epilepsia o el Parkinson, además de que se puede prolongar el tiempo del experimento.

Tabla 3.1. Ventajas y desventajas de las técnicas de interpretación de imágenes cerebrales
(continuación).

TÉCNICA	VENTAJAS	DESVENTAJAS
UD	<ul style="list-style-type: none"> ✓ Se puede utilizar para prevenir algunas enfermedades como lo es la Hipercolesterolemia o alguna <i>BSD</i> hemorrágica [Escudero, 2015]. ✓ Herramienta ultrasonográfica rápida, fácil de usar, de bajo costo, indolora y no representa riesgo ya que no utiliza radiación ionizante [Fernández, 2012]. ✓ Detecta si existe sangrado intracraneal u obstrucción así como tejidos blandos [Alet, 2015]. 	<ul style="list-style-type: none"> ✓ La ausencia de una ventana ósea craneal que no permite la penetración del ultrasonido en zonas como el polígono de Willis, lo que hace que la interpretación de los resultados en esta sección o en casos con lesiones arteriales bilaterales no se diagnostiquen de manera correcta [Matamoros, 2009].
CT	<ul style="list-style-type: none"> ✓ Crea una serie de imágenes transversales del cerebro que detectan anomalías pequeñas [Pukish, 2013]. ✓ Elimina la superposición de sombras en la imagen obtenida. ✓ Permite determinar tamaños y sobre todo una aproximación del tejido estudiado. 	<ul style="list-style-type: none"> ✓ Se realiza mediante la aplicación de Rayos X (para algunos pacientes puede representar un riesgo). ✓ Es necesario el uso de contraste intravenoso.
MRI	<ul style="list-style-type: none"> ✓ Revelar la ubicación, tamaño y presencia de algún aneurisma [Blanco, 2011]. ✓ No utilizan radiación como la CT. ✓ Gran capacidad en distinguir entre materia gris y blanca. ✓ Posibilidad de hacer estudios vasculares sin aplicar material de contraste [DespotoviT, 2015]. 	<ul style="list-style-type: none"> ✓ Se requiere de la colaboración del paciente (respiración, mantenerse quieto, etc.) durante la obtención de las <i>MRI</i>, ya que esto puede provocar ruido y variación paramétrica, debido a esto, es importante evaluar cada imagen y calcular cada uno de sus píxeles con el fin de suavizar los datos [Menze, 2016]. ✓ Pacientes con marcapasos o con algunos implantes corren un peligro inherente al campo magnético de alto poder.

3.3 Análisis de imágenes

Para algunos autores como [Isoardi, 2010], el estructurar una imagen en un sistema de reconocimiento artificial (como lo es el análisis automatizado de imágenes), consta de diferentes etapas, como se muestra en la Figura 3.6.

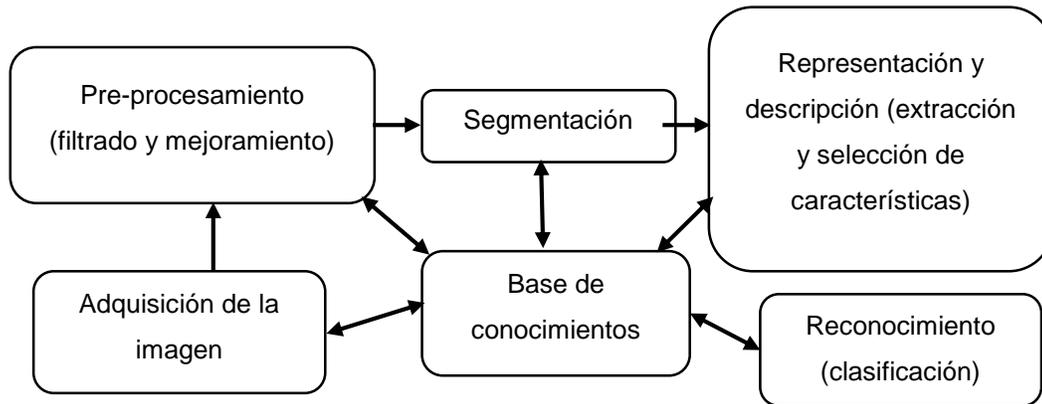


Figura 3.6 Etapas comunes (no aplicables en algunos casos) en la interpretación de imágenes médicas [Isoardi, 2010].

Al comparar la tarea de reconocer patrones de forma humana contra la AV, se tiene que para el ser humano esta tarea es una de las primeras habilidades que se aprende desde el momento de su nacimiento, convirtiéndose con el paso del tiempo en una tarea sencilla a partir de conocimientos previos (Figura 3.7), mientras que para una computadora, cuando ésta adquiere una imagen, la transforma en una matriz cuya dimensión depende del tamaño y resolución de la imagen (Figura 3.8), es decir, el conjunto de valores de píxeles que forman la imagen se agrupa en un número de columnas y filas iguales al tamaño de la misma [Baume, 2011].

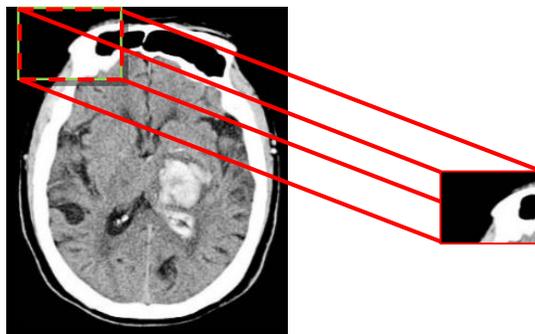


Figura 3.7 Ejemplificación de la visión humana [Deshpande, 2018].

3.4 Filtrado de imágenes

Se trata de métodos para resaltar o suprimir, de forma selectiva, información contenida en una imagen a diferentes escalas espaciales, para destacar algunos elementos de la imagen, o también para ocultar valores anómalos.

Como se describió anteriormente, cuando se aplican filtros a una imagen, es necesario elegir una matriz con valores de intensidad de pixeles, por lo que el filtrado de una imagen consiste en una operación local que modifica el valor de cada posición de los pixeles de una imagen considerando los valores que poseen los pixeles circundantes. El resultado final se divide entre un escalar, generalmente la suma de los coeficientes de ponderación, ésto con el único propósito de extraer información cuantitativa que debe almacenarse como una nueva matriz [Ruiz, 2015].

La técnica de filtrado puede ser descrita como la siguiente ecuación:

$$f[x, y] * g[x, y] = \sum_{n=1}^N \sum_{m=1}^M f[n, m]g[x - n, y - m] \quad (3.1)$$

Tabla 3.2 Parámetros de la técnica de filtrado [Ruiz, 2015].

	Descripción
N, M, n, m	Tamaño (ancho y alto) de la imagen
f	Aplicación del filtro
g	Tamaño de la máscara
x, y	Posición del pixel en la imagen

Donde la imagen es de tamaño $N \times M$, el filtro g a aplicar corresponde en realidad a una máscara o amplitud de ventana con área definida que recorre la imagen.

Conforme el filtro f va deslizándose en la imagen, se va obteniendo una matriz de números (pesos o parámetros), los cuáles se multiplican con los valores de los pixeles originales de la imagen (este proceso también es conocido como *Computing Element Wise Multiplications*), estas multiplicaciones se resumen generando sólo un número, es decir, la aplicación del filtro equivale a sobreponer la máscara en la posición $[x, y]$ de la imagen, y calcular la suma de los productos entre los elementos correspondientes de la máscara y de la imagen original [Ruiz, 2015], como se ejemplifica en la Figura 3.9.

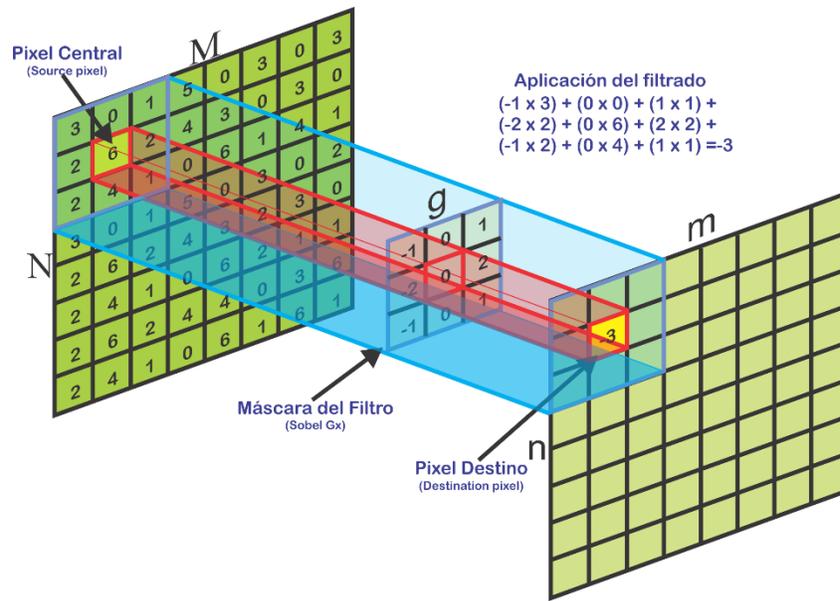


Figura 3.9 Operación de convolución para filtrado lineal en un punto de una imagen [Ruiz, 2015].

A la matriz resultante, generada por el deslizamiento del filtro por todas las ubicaciones de la imagen, se le conoce como *mapa o vector de características*.

Según [Bohte, 2017] los filtros se pueden dividir de acuerdo a las características que examinan, enfatizando que la técnica de filtrado permite suavizar, restaurar, mejorar y segmentar imágenes, obteniéndose características relevantes que pueden describir a la misma (Tabla 3.3).

Tabla 3.3 Definición y características de filtros [Baume, 2011].

FILTROS	Suavizado (<i>smoothing</i>)	Detección de bordes (<i>edge detection</i>)	Restauración de imágenes (<i>restauration</i>)	Morfología (<i>morphology</i>)	Segmentación (<i>segmentation</i>)
Utilizados para:	Eliminar ruido y conservar detalles significativos de la imagen.	Realzar rasgos lineales.	Evidenciar particularidades de una imagen como el fondo y contraste.	Realzar la geometría y forma de los objetos.	Realzar bordes
Ejemplos	Gaussiano Mediano	<i>Prewitt</i> <i>Sobel</i>	Histograma Inverso	Dilatación Erosión	Escala de grises Laplaciano

Finalmente, cada uno de los filtros puede considerarse como un identificador de características, dicho de otra manera, estudian entre sí las características más simples que todas las imágenes tienen en común.

3.5 Redes Neuronales Artificiales (ANNs)

La *AI* es un campo de estudio que pretende dotar a los computadores de algunas características del pensamiento humano, tales como la habilidad para encontrar soluciones a los problemas, basándose en la experiencia pasada, por lo que la información aprendida se convierte en conocimiento.

De esto surge como inspiración el estudio de las redes neuronales, cuya fuente está en el sistema nervioso central humano (específicamente en el cerebro), por lo que una de las metas principales de la *AI*, es el de alcanzar algunas de las ventajas que tienen estas redes neuronales biológicas, al punto de imitarlas desde su manera morfológica como funcional, dando como origen a las *ANNs* [Lluís, 2013].

En [Salas, 2011] la red neuronal es definida como “un sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona”.

Según [Ramírez, 2011] nuestro cerebro está compuesto por un conjunto de neuronas biológicas, las cuáles son descritas como células altamente especializadas en el proceso de la información, cuya estructura básica o morfología puede observarse en la Figura 3.10 [Aguilar, 2012], comprendiendo 4 elementos importantes:

1. Dendritas (*dentrites*): partes que reciben las señales de otras neuronas.
2. Soma o cuerpo de la célula (*cell body*): donde se suman todas las señales entrantes para generar una entrada.
3. Axón (*axon*): cuando la suma alcanza un valor umbral, la neurona se dispara y la señal viaja por el axón hasta otras neuronas.
4. Sinapsis (*synapsis*) (Figura 3.11): es el punto de interconexión de una neurona con otras neuronas. La cantidad de señal transmitida depende de la fuerza (pesos sinápticos) de las conexiones.

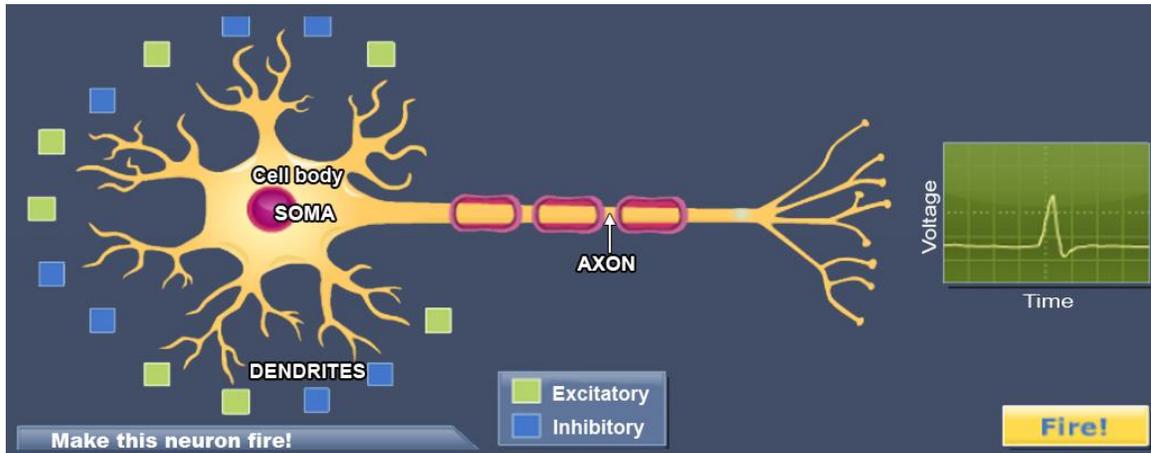


Figura 3.10 Partes de una neurona biológica (fuente *Children's Hospital Boston*) [Aguilar, 2012].

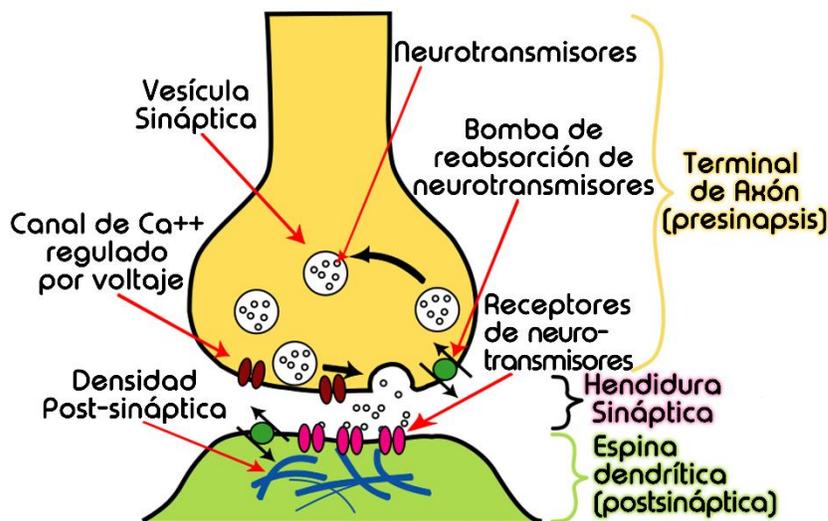


Figura 3.11 Neurona biológica, se observa su funcionamiento y las partes principales de su sinapsis. [Aguilar, 2012].

Como se describió antes, biológicamente las neuronas contienen un axón que está conectado a las dendritas de otra neurona a través de la sinapsis. Tales estructuras tienen la capacidad de "bombear" cargas eléctricas desde el medio intracelular a la neurona postsináptica. La cantidad de carga es una característica de la sinapsis específica y del neurotransmisor específico en uso. En las ANNs, para desarrollar un modelo matemático que reproduzca dicho proceso, se utilizan diversos parámetros

(peso sináptico, retardo sináptico, función de corriente sináptica, etc.) para representar las características de cada sinapsis (Figura 3.12).

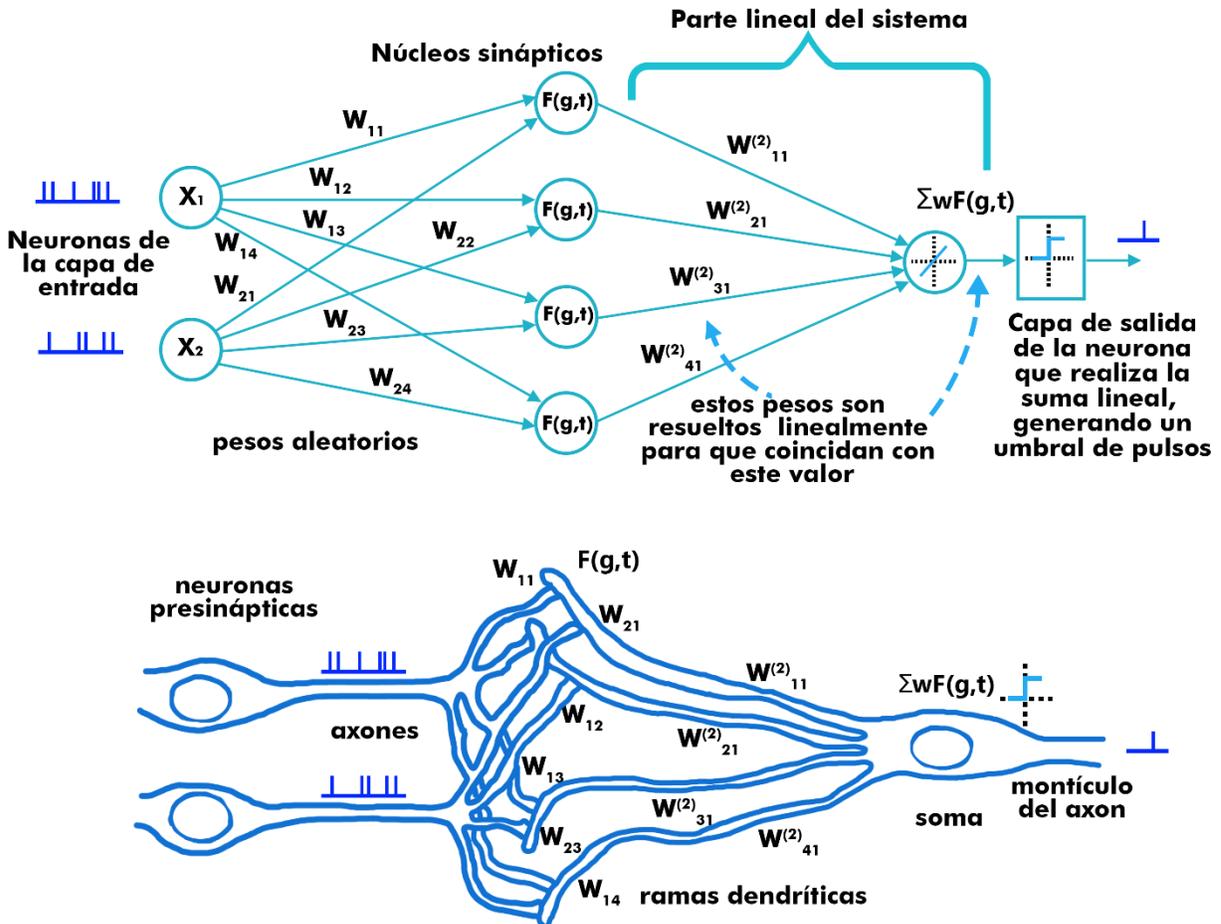


Figura 3.12 Ejemplificación de una sinapsis en el proceso de aprendizaje. [Tapson, 2013]

Análogamente a partir del estudio de este proceso, se formula la ANN la cual, de manera similar a una biológica, cuenta con entradas de datos y salidas, que se conectan con otras neuronas, las cuales son representadas por nodos (Figura 3.13), estos nodos pueden catalogarse como de:

- Entrada: aquéllos que reciben información del exterior.
- Salida: aquéllos que transmiten la información al exterior.
- Ocultos: aquellos que no tienen ningún contacto con el exterior y solamente intercambian información con otros nodos de la red, por lo que se encuentran fuertemente interconectados entre sí, organizándose por capas (monocapas y

multicapas), adquiriendo valores de los nodos de entrada, que se van modificando en un proceso llamado aprendizaje o entrenamiento.

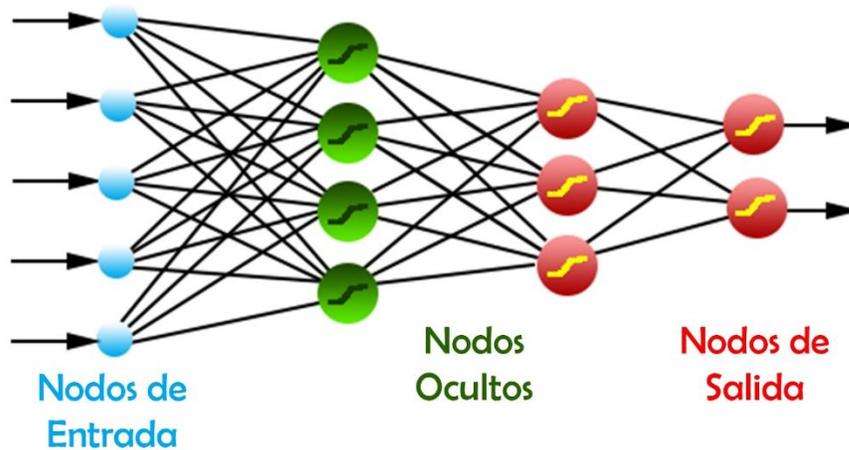


Figura 3.13 Arquitectura de una red con conexiones hacia adelante. Se distinguen los 3 tipos de nodos que puede contener una ANN [Larrañaga, 2015].

Respecto a esto, se puede decir que las ANN tienen un enfoque diferente, para la resolución de problemas con respecto a las computadoras convencionales, es decir, emulan ciertas características propias de los humanos, como la capacidad de memorizar y de asociar hechos (experiencia), en la Tabla 3.4 se muestran algunas analogías [Salas, 2011]:

Tabla 3.4 Comparación entre neuronas biológicas y las ANNs [Salas, 2011].

Redes Neuronales Biológicas	Redes Neuronales Artificiales
<ul style="list-style-type: none"> • Variedad de modelos de neuronas • Conexiones sinápticas • Efectividad de las sinápsis • Efecto excitatorio o inhibitorio de una conexión • Efecto combinado de las sinápsis • Activación -> tasa de disparo 	<ul style="list-style-type: none"> • Algunos modelos de neuronas • Conexiones ponderadas • Peso de las conexiones • Signo del peso de una conexión y algoritmos con modelos de pulsos. • Función de propagación o de red • Función de activación -> Salida

Por lo que las ANN son un modelo artificial y simplificado del cerebro humano, que es el ejemplo más perfecto del que se dispone para un sistema que es capaz de adquirir conocimiento a través de la experiencia.

Históricamente el origen de las ANNs data en 1943, con los trabajos de McCulloch y Pitts quienes propusieron un modelo abstracto electrónico de ANN, este modelo se considera como el más simple y básico de una ANN, la Figura 3.14 muestra su esquema:

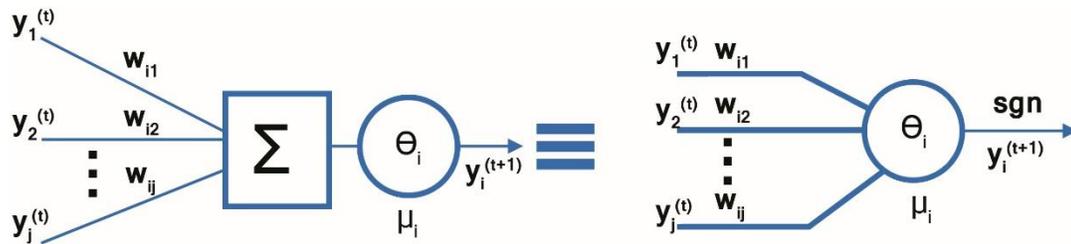


Figura 3.14 Modelo básico de McCulloch-Pitts [Salas, 2011].

Otro trabajo importante, se desarrolló en 1957, Rosenblatt representó un modelo de ANN, a la que nombró “Perceptron”, esta red es capaz de efectuar tareas de clasificación binaria, si bien mostró rápidamente sus limitaciones, subsiguientes modificaciones (Rumelhart y McClelland) dieron origen a los perceptrones de múltiples capas (en inglés, *Multi-Layer Perceptron*) que se utilizan actualmente en numerosas tareas de clasificación (Figura 3.15).

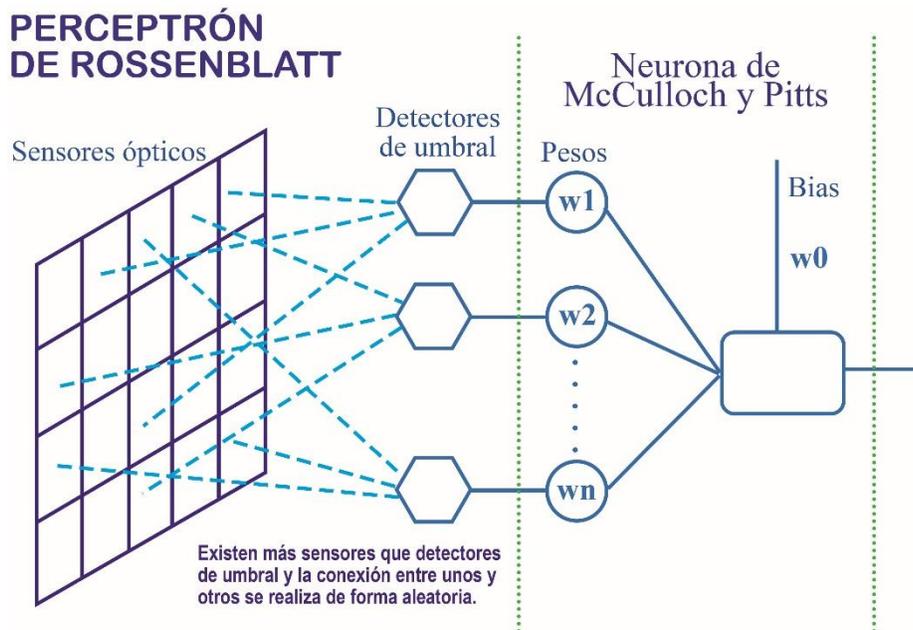


Figura 3.15 Perceptron de Rosenblatt [Banda,2015].

Una parte importante de las ANN, es la función de activación que contiene ya que calcula el estado de actividad de una neurona. Con el tiempo, se fueron realizando diferentes estudios y modificaciones, en la manera de “aprender” de las neuronas (Figura 3.16), lo que dio cabida a su clasificación por generaciones, de acuerdo a la función que utilizan para su procesamiento.

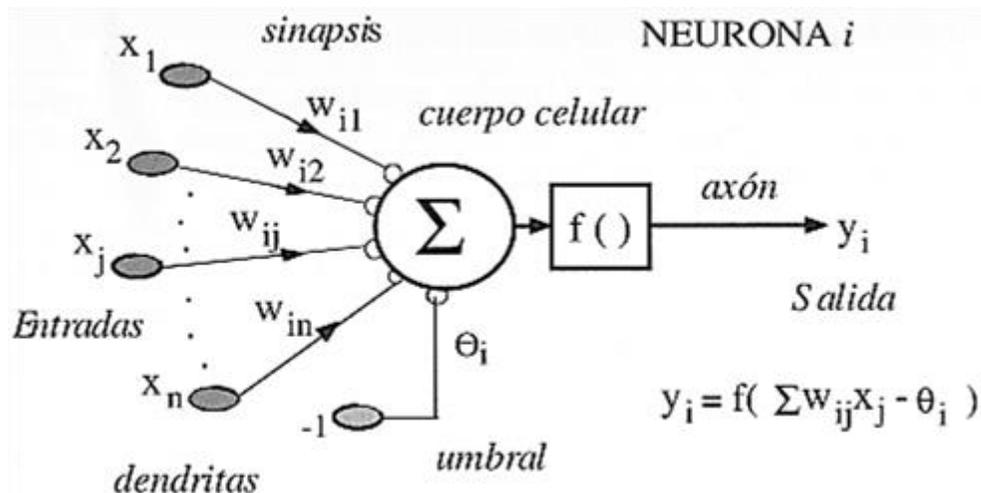


Figura 3.16 Modelo de neurona artificial estándar, $f()$ simboliza la función de activación utilizada en el aprendizaje.[Lujano,2014]

Si las ANNs se clasifican según unidades de procesamiento computacionales (es decir, neuronas y sinapsis), es posible distinguir tres clases de algoritmos [Maass, 1997] que difieren entre ellos por los tipos de señales de entrada-salida que pueden procesar y emitir: señales binarias, valores continuos y eventos de pico (ver Figura 3.17), mediante este concepto las ANNs se dividen en tres generaciones.

- ✓ Primera Generación: Presenta las ANN básicas, también llamadas Perceptrones, los cuáles se componen de dos secciones: una suma y un umbral. La parte suma recibe información de un conjunto de sinapsis ponderadas (en la Figura 3.17 w_1, w_2, \dots, w_N representa el conjunto de pesos de entrada) y realiza una función de umbral sobre el resultado de la suma. Tanto la entrada como la salida tienen valores que pueden ser 0 o 1 (valores discretos).

- ✓ Segunda Generación: Presenta neuronas con unidades sigmoideas. Las entradas pueden ser cualquier número de valor real, y la salida se define mediante la función de transferencia: la unidad sigmoidea, por ejemplo, limita las salidas a $[0; 1]$, mientras que la función hiperbólica produce salidas en el rango $[-1; 1]$.
- ✓ Tercera Generación: Están compuestas por neuronas adicionadas, que se comunican a través de señales cortas llamadas pulsos o *spikes*. En comparación con las dos generaciones anteriores, este grupo introduce el concepto de tiempo en la simulación, lo que las hace mucho más parecidas a las biológicas, ya que ambas se comunican usando señales cortas que biológicamente son impulsos eléctricos (*spikes*), también conocidos como Potenciales de Acción.

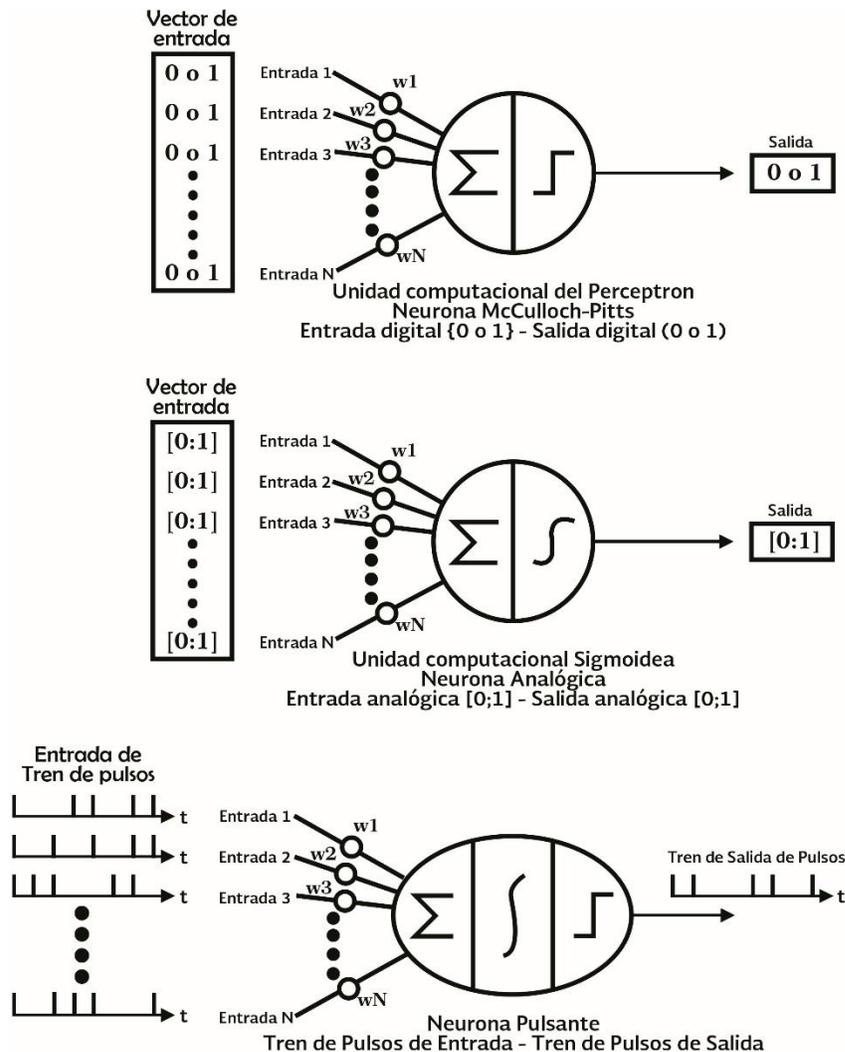


Figura 3.17 Clases de ANNs de acuerdo a su generación.[Davies,2012]

3.6 Redes Neuronales Artificiales Pulsantes (SNN)

Como se mencionó anteriormente, la función principal de una neurona es el de transmitir información, las ANNs del tipo Pulsante (SNN) pertenecientes a la tercera generación, incrementan su nivel de realismo incorporando la variable del tiempo al simular una neurona (Figura 3.18); en términos generales la función de una SNN es transmitir información a partir de pulsos o *spikes*.

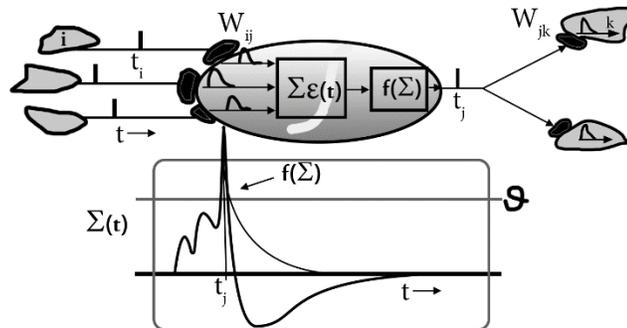


Figura 3.18 Esquema de una SNN en [Bohte, 2003]

Biológicamente el proceso global de transmisión de un pulso nervioso, puede ser dividido en varias fases: el potencial de reposo, el potencial de acción, el desplazamiento o flujo del potencial de acción a lo largo del axón, y la transmisión sináptica (Figura 3.19a); dependiendo de los parámetros neuronales la neurona puede comportarse de diferentes maneras (Figura 3.19b).

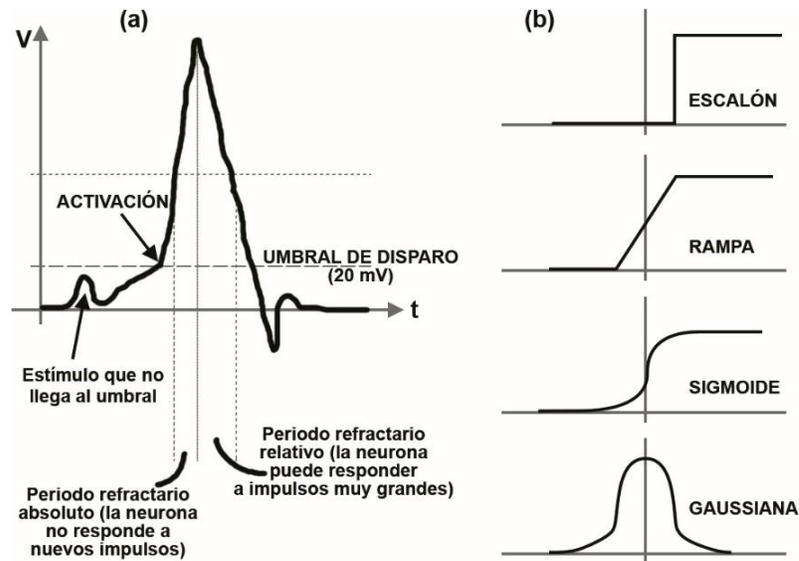


Figura 3.19 a) Partes del funcionamiento de una neurona, b) funciones de las que se rige el umbral de disparo [Marrero, 2018].

Por lo tanto, las partes importantes de una *SNN* son (Figura 3.20):

- Una *variable de estado*, que representa el potencial de membrana de la neurona, biológicamente es la diferencia de potencial eléctrico entre el interior de una neurona, y el medio extracelular circundante.
- El potencial de reposo: se llama así al estado en que se encuentra una neurona que no está transmitiendo información o pulsos. En su estado de reposo la neurona está en un estado de tensión, lista para disparar, o sea, para iniciar una transmisión.

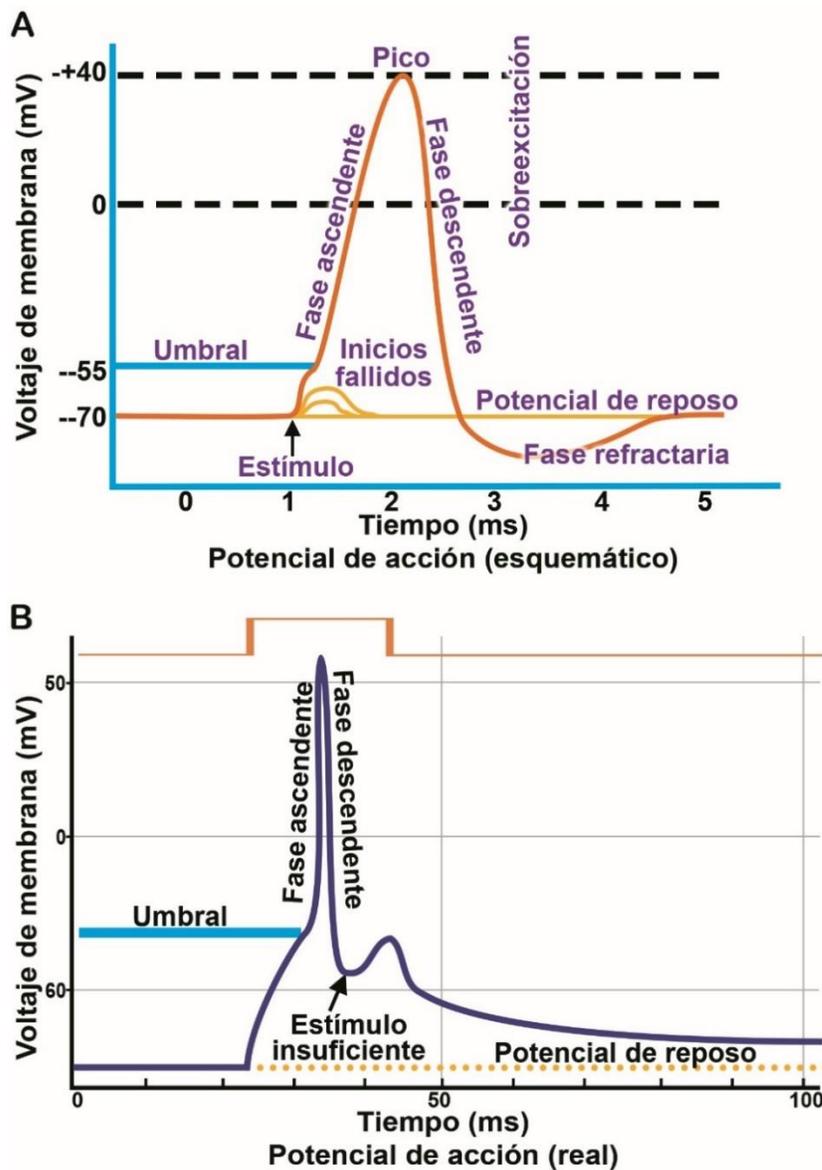


Figura 3.20 Fases del proceso global de transmisión de un pulso nervioso (*spike*) [Merino, 2011].

- El potencial de acción (spike): es el nombre con el que se designa un cambio drástico en la neurona, es decir el cambio se suscita cuando se recibe algún tipo de estimulación que genera un disturbio o pulso. La única señal que se puede propagar en larga distancia, lleva información (Figura 3.21).

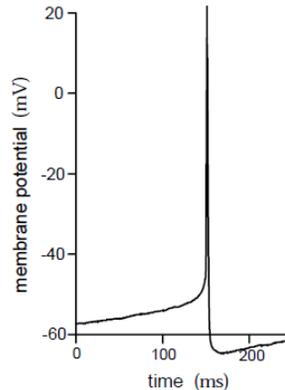


Figura 3.21 Los potenciales de acción transmiten información a través de su tiempo o frecuencia.
[González,2010]

- Flujo de potencial de acción: es la conexión entre neuronas, se divide en presináptica (inhibitoria) y postsináptica (excitatoria) (Figura 3.22).

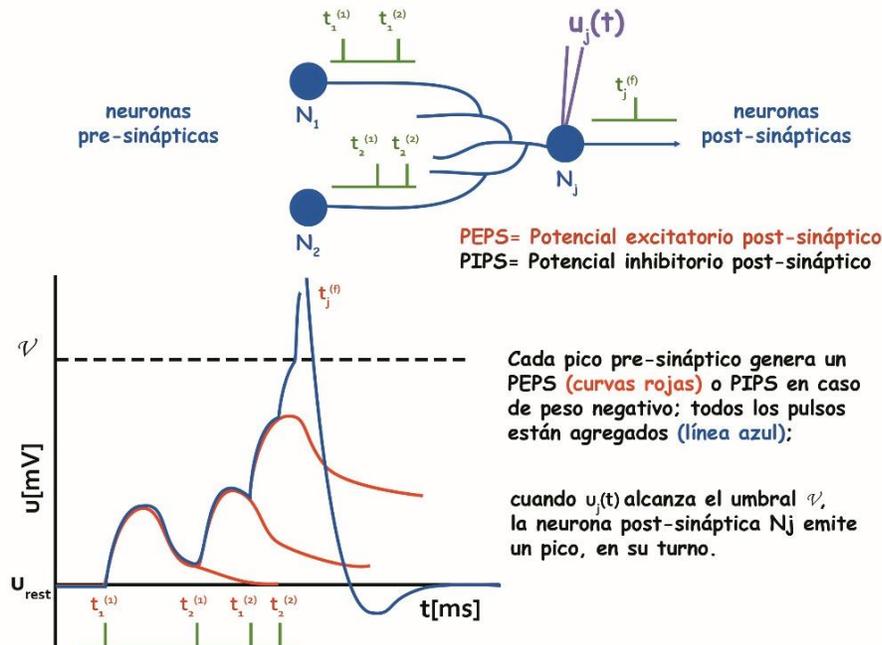


Figura 3.22 Ejemplificación del desplazamiento o flujo de información del potencial de acción.
[Paugam-Moisy,2006]

- Tren de pulsos: también llamada serie temporal, está formada a través de los potenciales de acción que transmiten información necesaria para la percepción y procesamiento, mediante su tiempo o frecuencia (Figura 3.23) [Maass, 1997].

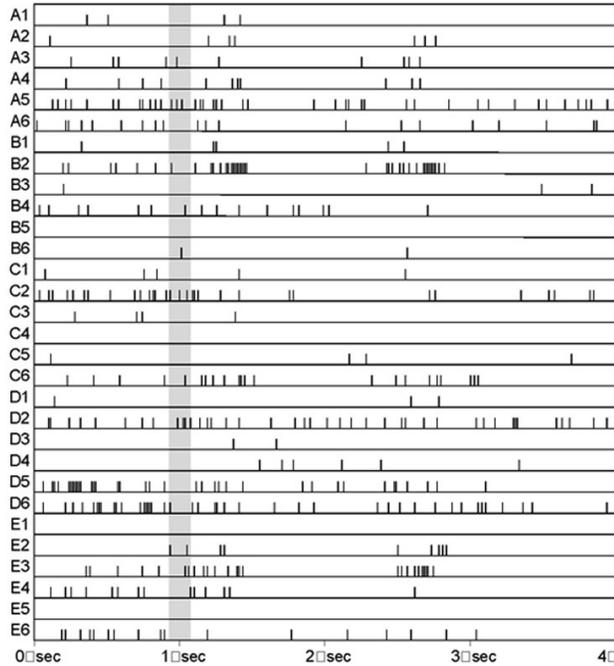


Figura 3.23 Tren de pulsos de 30 neuronas en la corteza visual de un mono [Maass,1997].

- Picos o pulsos: es la abstracción del potencial de acción (Figura 3.24).

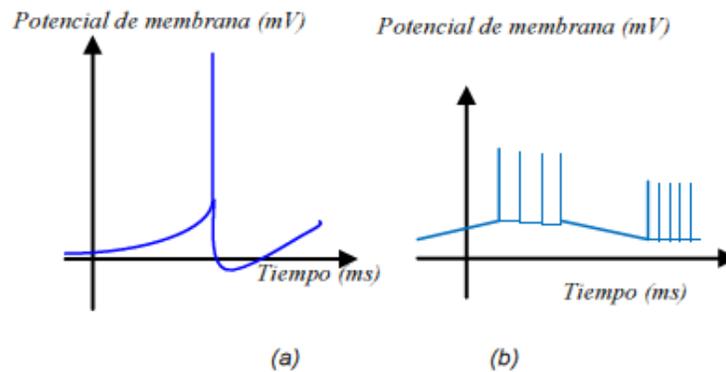


Figura 3.24 Potenciales de Acción a) Pulso en Sinapsis b) Tren de pulsos [Ramírez, 2011].

Dentro de las *SNNs* existen diferentes algoritmos o reglas de aprendizaje, las cuáles dictan que conexiones se harán más o menos significativas, de esta manera, se toma una decisión sobre cuál entrada es más importante con base en el modelo que se esté aplicando.

3.7 Clasificación de las redes neuronales Pulsantes.

Con base en diferentes estudios consultados en el estado del arte (Capítulo 2), se hallaron diversas estructuras que pretenden modelar el comportamiento de las *SNNs*, con ello se obtuvo la Tabla 3.4, mediante la cual se hace una clasificación de las *SNN* de acuerdo a los modelos, topologías y aprendizaje frecuente que realizan, enfatizando que la capacidad de cada uno de los modelos para reproducir patrones de disparo se encuentra en la topología y el aprendizaje utilizado.

[Izhikevich, 2004] compara varios de estos modelos de neuronas en términos de significado biofísico, generando la gráfica de la Figura 3.25, en la cuál define el comportamiento de cada uno de éstos, las características de los diferentes pulsos que reproducen, y la complejidad computacional que necesitan para ser simulados. De acuerdo a su simplicidad computacional y modelado de una neurona biológica, en la Tabla 3.5 destaca el modelo Izhikevich.

Tabla 3.5 Clasificación General de una *SNN*.

MODELOS GENERALES	TOPOLOGÍAS	APRENDIZAJE FRECUENTE
➤ Hodgkin-Huxley [Salas, 2011]	<u>Feedforwards</u> ➤ Izhikevich [Izhikevich, 2003]	<u>Supervisado</u> [Grüning, 2007] ➤ Izhikevich [Izhikevich, 2003] ➤ Supervised Hebbian Learning (SHL) ➤ ReSuMe (Ponulak) ➤ SpikePro (Ponulak) ➤ Backpropagation ➤ Sinaptic Plasticity ➤ Temporal coding based models ➤ Convolution of Spike trains
➤ Thorpe's model		
➤ FitzHugh-Nagumo [Izhikevich, 2004]		
➤ Izhikevich [Izhikevich, 2003]		
➤ HindMarsh-Rose	<u>Recurrentes</u> ➤ Izhikevich [Izhikevich, 2007]	<u>REforcement learning</u> • Agent-environment interface • Markov decisión • Temporal-different learning
➤ Wilson		
➤ Morris-Lecar		
<u>Integrate-and-Fire</u>	<u>Híbridas</u> ➤ SynfireChains ➤ Reservoir Computing	<u>No Supervisado</u> [Clopath, 2010] • Spike-Time-Dependent-Plasticity (STDP) • ReSuMe • Hebbian rule • Rank order (RO) • BCM rule
➤ Integrate-and-Fire(IF)		
➤ Leaky-Integrate-and-fire(LIF)		
➤ Quadrati Integrate-and-Fire (QIF)		
Spike Response Model (SRM)		

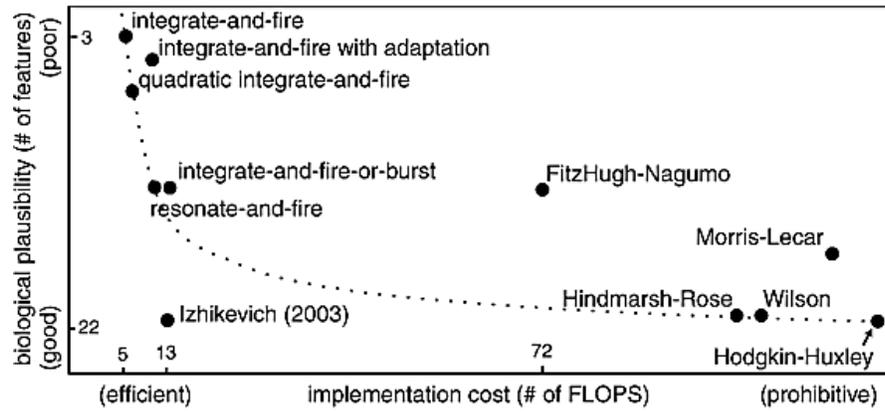


Figura 3.25 Comparación costo-plausibilidad de diferentes modelos de SNNs [Izhikevich, 2004].

3.7.1 Modelo Izhikevich

Llevando el nombre de su autor [Izhikevich, 2003], este modelo neuronal se describe eléctricamente de manera simple, por un sistema de dos ecuaciones diferenciales ordinarias (3.2 y 3.3), que permiten ajustar el comportamiento y forma de disparo de una neurona (3.4):

$$C\dot{v} = k(v - v_r)(v - v_t) - u + I \quad (3.2)$$

$$\dot{u} = a(b(v - v_r) - u) \quad (3.3)$$

$$Si v \geq v_{peak}, \quad v \rightarrow c, u \rightarrow u + d \quad (3.4)$$

Tabla 3.6 Parámetros de la neurona Izhikevich

Parámetro	Definición
C	Capacitancia
k	Forma del pico o disparo
v	Potencial de membrana
v_r	Valor del reposo de la membrana
v_t	Voltaje del umbral instantáneo
u	Variable de recuperación, es amplificador si $b < 0$ y restador si $b > 0$
I	Corriente aplicada al modelo (entrada de la neurona)
a	Constante de tiempo de recuperación
b	Constante de sensibilidad de la neurona
c	Voltaje de reinicio
d	Parámetro utilizado para restablecer la variable u después de un disparo.
$Si v \geq v_{peak}$	Condición para contar el número de pulsos generados.

Con base en los cuatro parámetros a, b, c y d , (Figura 3.26) es posible generar una de las 23 formas de la membrana de potencial de acción de una neurona, encontradas

en las neuronas de diversos mamíferos [Izhikevich,2003]. Sin embargo, hoy en día todavía no se utiliza ampliamente en las redes neuronales, ya que los comportamientos de pico más complejos aún no son controlables para el aprendizaje y la codificación de la información.

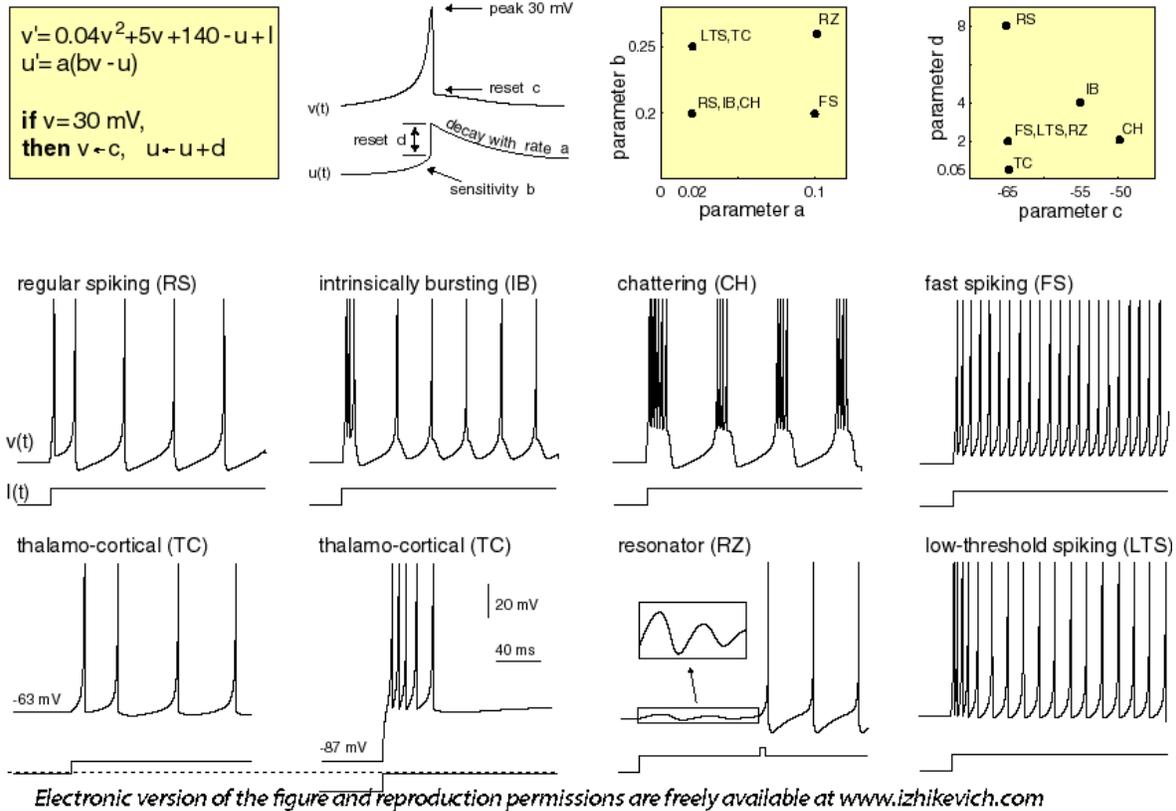


Figura 3.26 Ejemplificación de algunos potenciales de acción generados a partir del modelo de Izhikevich [Izhikevich, 2003].

3.7.2 Análisis del aprendizaje con una neurona Izhikevich

En [Hernández, 2017] el aprendizaje o entrenamiento se describe como *el proceso mediante el cual a un sistema se le da la capacidad de almacenar información y ajustar sus propios parámetros para hacer una identificación de los patrones*. De forma específica, en las redes neuronales mediante el entrenamiento se logra la clasificación y reconocimiento.

Tomando en cuenta el concepto anterior, es necesario recalcar que las *SNN*, a diferencia de otras *ANNs*, no poseen una salida representada por un valor, sino que las *SNN* generan conjuntos de pulsos o disparos generados durante un intervalo de tiempo.

De acuerdo al trabajo de [Matadamas, 2014], para que se pueda realizar el aprendizaje en una neurona Izhikevich, usando las dos ecuaciones diferenciales ordinarias (ecuación 3.2 y 3.3), es necesario primeramente expresar el parámetro I como una entrada al modelo, por lo que representa una corriente inyectada de manera directa a la neurona.

Así mismo la salida se considera con el parámetro v (que representa el potencial de membrana), la cual es la respuesta en el tiempo de la neurona al estímulo de entrada, el conteo realizado para cada estímulo se rige por la condición v_{peak} , cada vez que su valor condicional es rebasado o igualado, gráficamente el modelo se representa como (Figura 3.27).

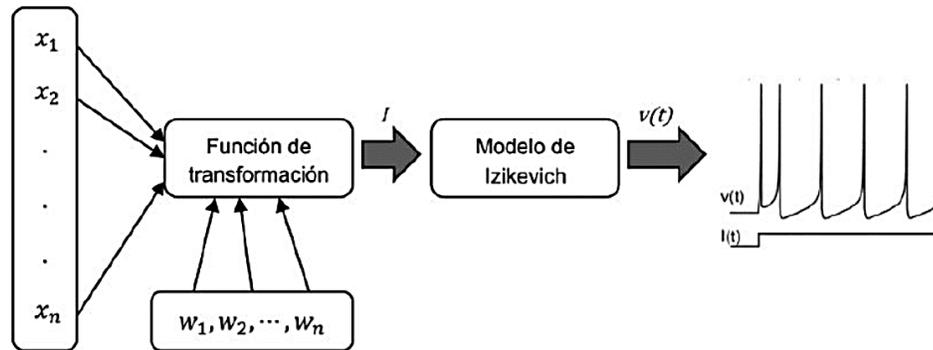


Figura 3.27 Funcionamiento del modelo de Izhikevich [Hernández, 2017].

Para conocer las limitantes del modelo de Izhikevich en cuanto a los pulsos producidos y corriente de entrada, [Matadamas, 2014] y [Hernández, 2017] hacen uso del patrón de pulsos regulares (*Regular Spiking (RS)*) dado por Izhikevich debido a que este comportamiento se presenta en un mayor número de neuronas encontradas en la corteza de los mamíferos [Izhikevich, 2007], cuyos valores son (Tabla 3.7):

Tabla 3.7 Valores de los parámetros de la neurona Izhikevich con respuesta de picos regulares [Izhikevich, 2003].

Parámetro	Valor
C	100
k	0.7
v_r	-60
v_t	-40
a	0.03
b	-2
c	-50
d	100
v_{peak}	35

En el estudio realizado por [Matadamas,2014], para generar picos en una dinámica de disparos del tipo *Regular Spike*, se obtuvo que los límites para la corriente de entrada de una neurona Izhikevich (anexo A del CD) está dada por:

$$51.9 \leq I \leq 11,883.4$$

Dentro de una frecuencia de disparos(fd) simulada de:

$$0 \leq fd \leq 999$$

Para así conocer la respuesta ante una simulación hecha para un intervalo de tiempo de 1 segundo, es decir la corriente mínima capaz de activar a la neurona (producir al menos un pulso) y la corriente máxima (el alcance máximo de muchos pulsos).

Como toda ANN, la SNN contiene como patrones de entrada un vector de características o rasgos, sin embargo, como se mencionó anteriormente, [Matadamas,2014] en el modelo de Izhikevich éstos vectores no pueden ser introducidos directamente, por lo que es necesario convertir este vector en una corriente I única, ésta corriente es calculada a partir de un vector de características $x_i \in \mathbb{R}^n$ de entrada en conjunto con un vector de valores $w_i \in \mathbb{R}^n$, que representan a los parámetros de una función de transformación, mediante la cuál gracias a la sintonización de parámetros, son mapeados a un valor escalar que corresponde a la corriente que activará la neurona.

En este trabajo la función utilizada fue la polinomial (ecuación 3.5):

$$I = (x \cdot w' + 1)^2 + \theta \quad (3.5)$$

En muchos casos, la corriente obtenida del cálculo de la función de transformación no es suficiente para hacer que la neurona pulsante se active, por lo que los valores más significativos se encuentran a partir de que el parámetro θ es igual a 55.

Describiendo a I en términos de pesos, [Hernández, 2017] nos queda (ecuación 3.6):

$$I = \left(\sum_{k=1}^n w_k x_k + 1 \right)^2 \quad (3.6)$$

[Hernández, 2017], en su análisis del descenso del error, genera la expresión de la ecuación 3.7 para incrementar los pesos de cada x_k , la cual hace uso de una tasa de aprendizaje representada por α :

$$\Delta w_i = -\alpha x_i (y - y') \left(\sum_{k=1}^n w_k x_k + 1 \right) \quad (3.7)$$

Tabla 3.8 Definición de los parámetros de la neurona Izhikevich.

Parámetro	Definición
I	Pulsos (variable de entrada)
y	Salida
y'	Salida deseada
α	Tasa de aprendizaje
w	Pesos
x	Entradas
θ	Pico del potencial de acción

Es importante recalcar que lo importante del modelo de Izhikevich radica en el número de pulsos generados (o disparados) durante un intervalo de tiempo y no en la forma elegida del pulso, para realizar este conteo se hace uso de la condición v_{peak} , la cual sirve como el límite en que un disparo genera un pulso.

3.8 Discusión

Las *BSD* son afectaciones que ocurren en los vasos sanguíneos del cerebro, siendo las isquémicas las más frecuentes y en algunas ocasiones pueden prevenirse.

Se consideró trabajar con Imágenes de Resonancia Magnética, debido a que son una fuente de obtención de imágenes cerebrales que contribuyen a la detección de diversas patologías y *BSD*, además de que realizan una identificación casi precisa por su gran capacidad de distinguir entre materia gris y blanca, esto respecto a otros tipos de fuentes utilizadas para reproducir imágenes cerebrales.

La *MRI* resultó de las menos invasivas ya que se realiza dentro de un campo magnético, y junto con la radio frecuencia altera el alineamiento natural de los átomos de hidrógeno en el cuerpo, estas imágenes no utilizan radiación como los hacen los rayos X o la Tomografía.

En cuanto a las imágenes generadas por *EEG* y Doppler, se descartaron ya que se descubrió que generalmente, sirven en el diagnóstico o corroboración de enfermedades específicas como lo son: el Alzheimer, Parkinson y enfermedades cognitivas.

Para la interpretación de las imágenes *MRI* mediante *ANNs*, la investigación se basó en las etapas descritas en la Figura 3.6, así como en métodos para la obtención de información como son las técnicas de filtrado.

Según la literatura encontrada, los algoritmos con mayor número de aplicaciones comerciales en la actualidad siguen siendo los pertenecientes al aprendizaje supervisado, siendo el modelo de Izhikevich el que simula de manera simple una *SNN*.

Como para el reconocimiento de imágenes cerebrales el objetivo principal de este tema de tesis son las *SNN*, se eligió trabajar bajo el modelo de Izhikevich, con una topología *feedforward* y con un aprendizaje supervisado.

CAPÍTULO 4. METODOLOGÍA DE LA SOLUCIÓN

En este capítulo se presentan los pasos previos a la experimentación, que sirven como guía para el logro de los objetivos planteados. Primeramente, se describe la implementación y entorno de desarrollo, los pasos de solución propuestos, el tipo de imágenes usadas en el reconocimiento de patrones, el procedimiento para su preprocesamiento, seguido de la obtención de datos de entrada para alimentación de la *SNN*, el diseño y su validación para realizar el análisis de imágenes.

4.1 Implementación y entorno de desarrollo

Para el funcionamiento en el desarrollo de las pruebas y experimentación se utilizaron las siguientes herramientas.

- Se contó con un equipo de cómputo con procesador Intel Core i7-5500U de 2.40GHz, 8 Gb de RAM, sistema operativo Windows 8 a 64 bits (www.microsoft.com/es-mx/windows).
- Eclipse versión Oxygen 2017 (<https://www.eclipse.org/oxygen/>)
- OpenCV 3.2 (<https://opencv.org/>)
- Matlab 2015a (<https://www.mathworks.com/matlab/R2015a.html>)

Se desarrollaron funciones como se muestra en la Tabla 4.1):

Tabla 4.1 Software utilizado en este tema de investigación.

<u>C++</u>	<u>MATLAB</u>
a. Función de Filtrado b. Neurona Izhikevich (función) c. ANN SNN	a. Función de Filtrado (<i>guide</i> y modelado) b. Neurona Izhikevich (función y modelado) c. Simulink

4.2 Pasos de la solución propuestos

Con el fin de comprobar el modelo de Izhikevich como simulación para clasificar imágenes mediante las *SNNs*, se siguió la metodología descrita en la Figura 4.1, cuyas partes se analizarán en las secciones siguientes:

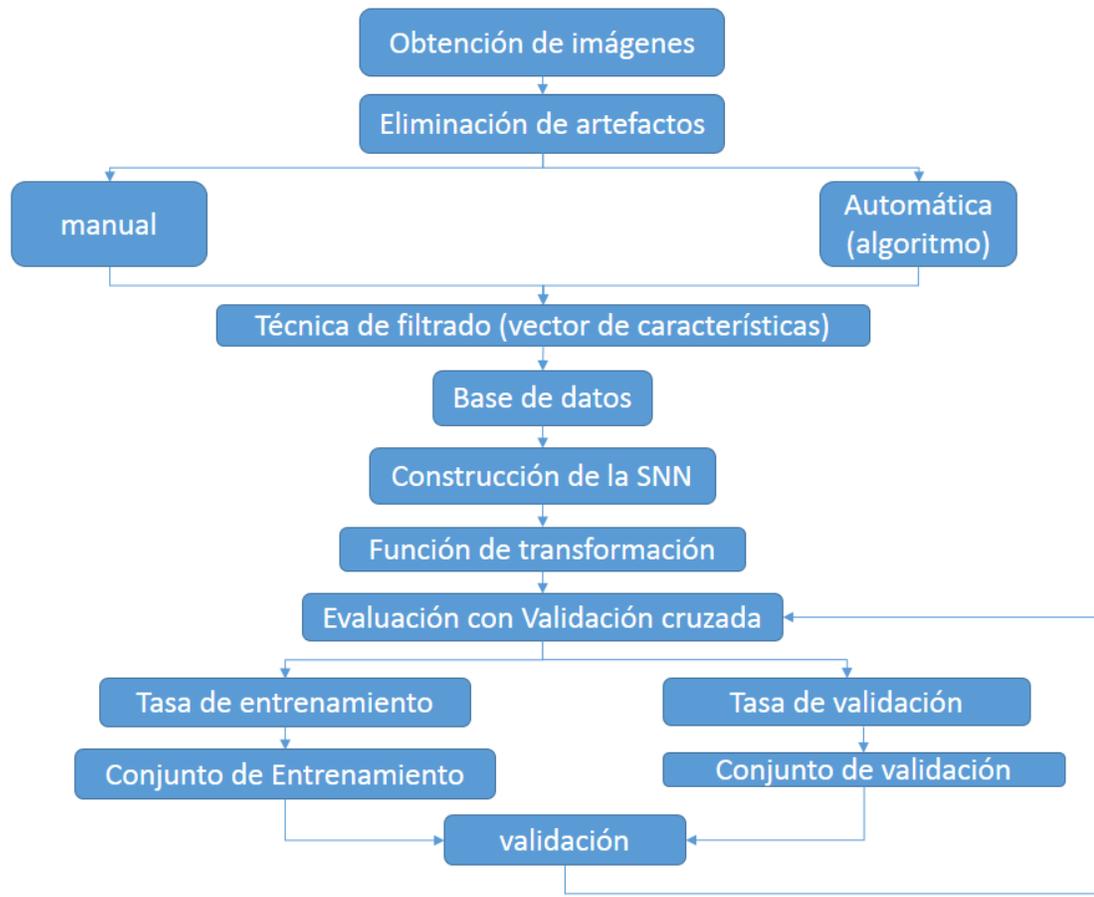


Figura 4.1 Metodología para los experimentos de clasificación de cerebros sanos y enfermos.

1. La experimentación se realizó mediante la unión en código abierto del lenguaje C++ y el programa de *OpenCV* (<https://opencv.org/>).
2. Se contó con imágenes *MRI* con un tamaño de 512x512 píxeles en formato *.jpg en escala de grises.
3. Se manipularon de forma manual las imágenes *MRI*, quitándoles los píxeles que correspondía al área exterior de la imagen cerebral, tomando como referencia el límite el cráneo; también se experimentó este preprocesamiento con una *guide* en Matlab (<https://www.mathworks.com>) usando la técnica “*skull stripping*” (Anexo B del CD).
4. Se implementaron en C++ 10 filtros con una máscara de 3x3 píxeles para generar un vector de características de las imágenes (<https://www.eclipse.org/oxygen/>). De

- igual manera se elaboró una plataforma de experimentación en el *guide* de Matlab con el fin de analizar y comparar los resultados de la aplicación de los filtros.
5. Los resultados fueron almacenados en archivos *.txt.
 6. Se normalizaron los resultados obtenidos de la aplicación de filtros en un rango de [0,1].
 7. En la etapa de entrenamiento los datos generados y almacenados de los archivos *.txt fueron divididos mediante la técnica de validación cruzada.
 8. Se implementó una simulación para la clasificación de imágenes con una red neuronal del tipo *Multi-Layer Perceptron* en C++.
 9. El comportamiento de la generación de pulsos de la neurona Izhikevich, se implementó una función en C++ y Matlab para su simulación.
 10. Se implementó la clasificación de imágenes mediante la *SNN* en C++.
 11. Se estudiaron los mejores parámetros arrojados en la *SNN*.
 12. Se implementaron los porcentajes de 100%, 90%, 85% y 75% del total de los datos a analizar en la fase del entrenamiento de imágenes de la *SNN*.
 13. Se usaron los valores de $\theta = 35$ y 45 en la corrida de las *SNNs*.
 14. Se hicieron los cambios en $\alpha = 0.02$ y 0.05 en la tasa de aprendizaje.
 15. Se realizó el cálculo del *accuracy* en el aprendizaje y en el reconocimiento.

4.3 Adquisición de imágenes

Las diferentes imágenes se obtuvieron de colecciones gratuitas de radiología educativa pertenecientes a *MRIs* de pacientes que presentaban algún tipo de *BSD* isquémica, halladas en la página <https://radiopaedia.org> y <http://www.strokecenter.org/radiology/patients>.

También se hizo uso de la base de datos citada en [Hernández, 2017] ubicada en <http://insight-journal.org/midas/community/view/1858>.

La base de datos obtenida se compone por 111 elementos en total (50 con cerebros enfermos y 61 con cerebros sanos).

4.4 Preprocesamiento y eliminación de artefactos

El preprocesamiento de una imagen [Cortés-Martínez, 2017] consiste en aplicar técnicas para la búsqueda de datos a partir de una imagen original, mejorando sus características en otra imagen, con la finalidad de ser analizadas y que permitan realizar operaciones a partir de información hallada; aplicando esto a imágenes médicas, su papel es crucial para el tratamiento y diagnóstico de enfermedades.

Uno de los objetivos del preprocesamiento es el de normalizar o estandarizar los datos de una imagen previa. En algunos casos [Menze, 2016] no es necesaria esta etapa; en otros, por ejemplo [Abdulrahman, 2015], los artefactos presentes en las imágenes médicas suelen eliminarse manualmente.

En [Blanco, 2011] se define como un *artefacto* a la “estructura o un aspecto que no está normalmente presente en la radiografía y se produce por medios artificiales”, es decir, las imágenes originales contienen “detalles ajenos” (o artefactos) cuando presentan algún tipo de ruido o moteado, algunos de estos son derivados de los aparatos con los que se toman las muestras [Martínez-Vila, 2011] [Chawla, 2009], por lo que el resultado del diagnóstico del médico al paciente puede errar.

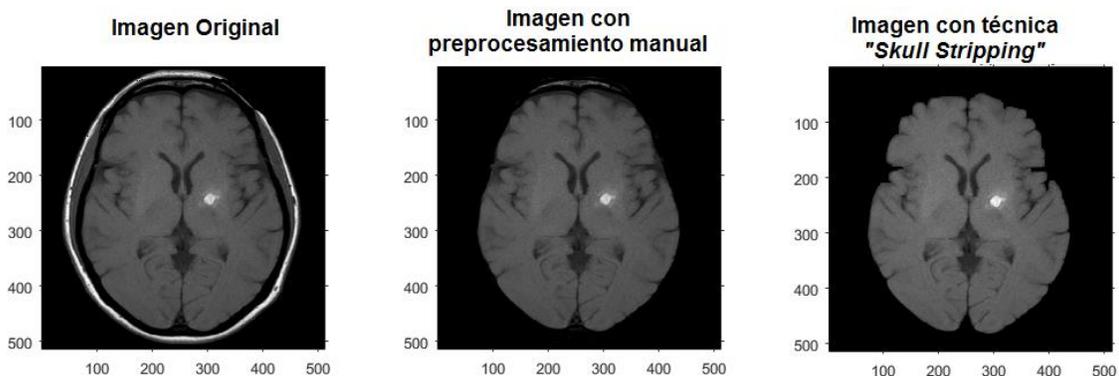


Figura 4.2 Preprocesamiento de imágenes cerebrales.

En el presente trabajo (Figura 4.2), se realizó de manera manual esta etapa, considerándose el tener una uniformidad de las imágenes obtenidas, cuya dimensión en el tamaño de las mismas fuera de 512x512 píxeles, bajo un formato *.jpg, teniendo como referencia el límite craneal de la imagen.

Como dato adicional a la experimentación, se hizo uso de la técnica “*skull stripping*” [Shaswati, 2015], la cual aísla la sección del tejido cerebral escaneado, mediante el cálculo del área de la materia blanca del cráneo.

4.5 Vector de características mediante el promediado de técnicas de filtrado

En la investigación realizada en [Cortés-Martínez, 2017] se identificó que diversos autores coinciden en que uno de los métodos más importantes en la adquisición de información, es el filtrado (Figura 4.3) [Chawla, 2009], puesto que además ayuda en el mejoramiento [Abdulrahman, 2015] y la eliminación de ruido sin afectar la nitidez de la imagen médica [Tajbakhsh, 2016].

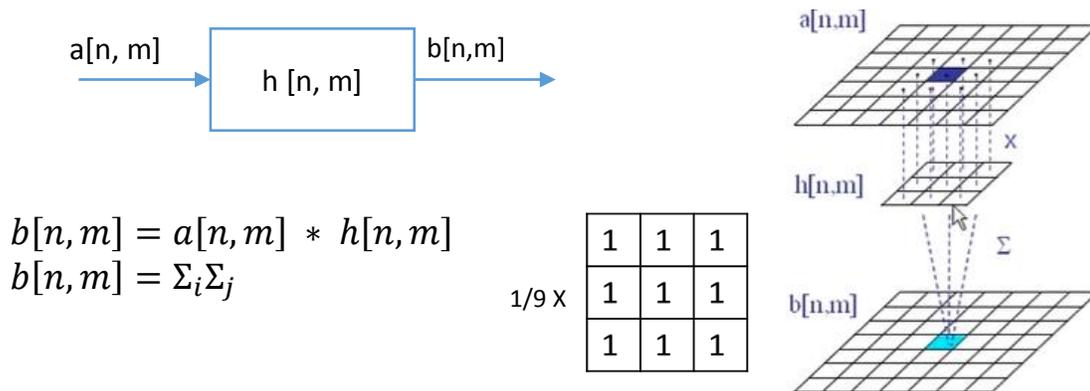


Figura 4.3 Ejemplificación de una máscara de filtrado [Chawla, 2009].

Con el fin de distinguir de alguna manera las imágenes de cerebros sanos de las imágenes de cerebros con anomalías, a partir del estudio de [Boudjelal, 2012] mencionado en la Tabla 3.3 del capítulo 3, se aplicaron esos diez filtros a las imágenes, para generar una base de datos con vectores de características que describieran a cada una de las imágenes, y sirvieran en la realización de pruebas y análisis de las ANNs, es decir, al aplicar a cada una de las imágenes cerebrales los diferentes filtros generaron un número representativo de los pixeles totales analizados de la imagen.

Los filtros utilizados contaron con una máscara de 3x3, cabe mencionarse que el filtro de escala de grises tuvo importancia en la aplicación en las imágenes, puesto que sirvió para estandarizar sus niveles de intensidad con un valor de 0 hasta 255.

Estos filtros se desarrollaron en C++, siguiendo el siguiente algoritmo (Tabla 4.2):

Tabla 4.2 Algoritmo de la técnica de filtrado para la obtención del vector de características

1	Convertir la imagen a escala de grises
2	Utilizar una máscara definida de 3x3 pixeles como vecindad para todos los filtros.
3	Aplicar los filtros de uno por uno a cada una de las imágenes.
4	Promediar los valores generados de los filtros, generando un número representativo por filtro.
5	Crear el vector de características de cada uno de los patrones formado por 10 elementos (filtros).
6	Guardar los resultados de los filtros en archivos *.txt
7	Normalizar las bases de datos, cada una de las características se localizan en un rango de entre 0 y 1. Para ello utilizar la siguiente ecuación: $DatoNormalizado = \frac{Dato - Dato_{min}}{Dato_{Máx} - Dato_{min}}$

Para comparar los resultados generados por los filtros en C++, se desarrolló una *guide* en Matlab (Figura 4.4), donde se obtuvieron valores de los diez filtros aplicados a una imagen, guardándose en un *.txt; también se experimentó con Simulink. Los resultados de la experimentación de las características obtenidas de los filtros se describen en la carpeta “03_BD vectores características”, y anexo E del CD.

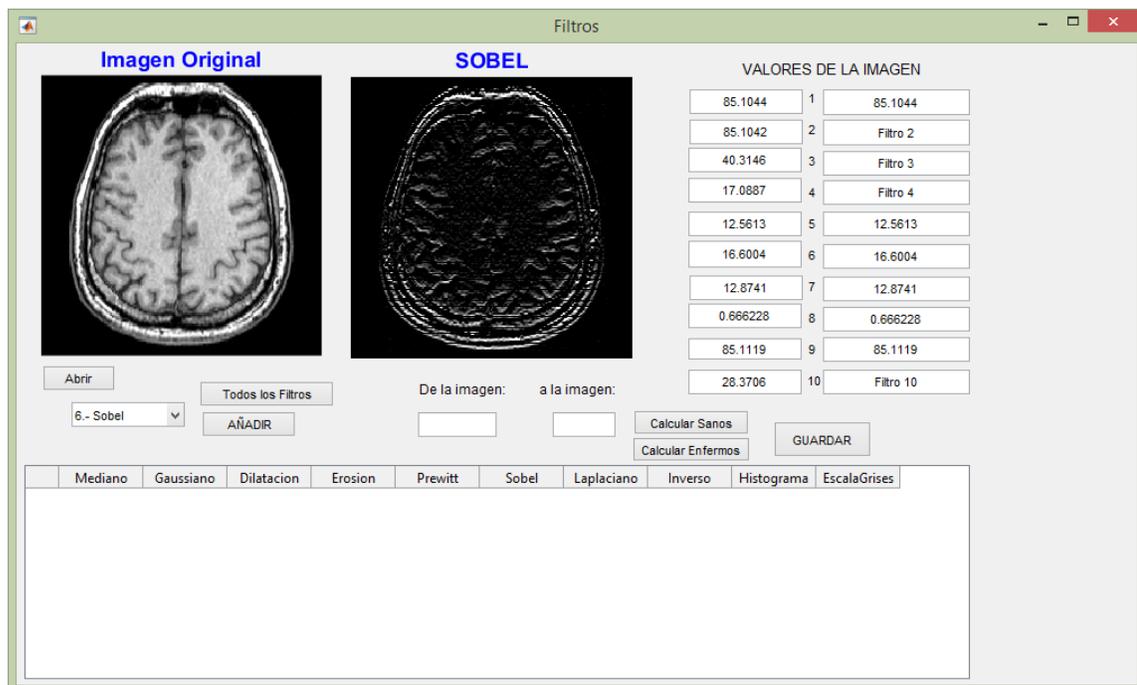


Figura 4.4 Guide en Matlab con aplicación de filtros.

4.6 Construcción de las ANNs

Una vez teniendo las bases de datos, se recurrió a diseñar una *ANN MLP* para comparar su funcionamiento con una *SNN*, debido a que se reportó en el estado del arte su uso frecuente en la aplicación de aprendizaje y clasificación de imágenes [Dridi, 2016], haciendo variación en el valor de la tasa de aprendizaje. Cabe señalar que, para lograr una clasificación mediante una *SNN*, los vectores de características de pertenecientes a la misma clase generaran frecuencias de disparo parecidas o iguales, con el fin de discriminar los vectores que generan frecuencias distintas, por lo que las clases utilizadas para las *ANNs* fueron (Tabla 4.3):

Tabla 4.3 Clases asociadas a las *ANNs*.

<i>ANN</i>	SANO	ENFERMO
<i>MLP</i>	1	0
<i>SNN</i>	2	5

Para asemejar los mismos parámetros usados en ambas *ANNs*, la experimentación se basó en los siguientes puntos:

- 1) Como método de aprendizaje de pesos y umbrales el algoritmo de gradiente descendente.
- 2) Los experimentos fueron hechos con distintos conjuntos de datos como se muestra (Tabla 4.4):

Tabla 4.4 Número de imágenes usadas en los experimentos

Experimento	Conjunto de datos	Sanos	Enfermos
1	50 imágenes	23	27
2	80 imágenes	40	40
3	85 imágenes	37	48
4	90 imágenes	48	42
5	92 imágenes	50	42

- 3) Sobre el conjunto de datos, haciendo uso de la técnica de validación cruzada, se usaron los porcentajes de 75%, 80%, 85% y 90% como referentes para el conjunto de entrenamiento y aprendizaje de las *ANNs*, con el propósito de evaluar los resultados mediante un análisis estadístico [Mangin & Mallou, 2006].

- 4) Se usaron como tasas de aprendizaje los valores 0.02 y 0.05, se analizaron y se trabajó con estos valores debido a que la tasa de aprendizaje de una ANN, depende de distintos factores controlables que hay que tener en cuenta, en este caso, al escogerse una tasa de aprendizaje pequeña la convergencia puede requerir más épocas, sin embargo, si la tasa es grande se puede provocar una oscilación en el modelo y la convergencia no se dará.
- 5) Ambas son del tipo *feedforward*.

En la siguiente sección se mostrará los elementos que componen a la SNN con modelo Izhikevich.

4.7 Arquitectura de la SNN usando el modelo de Izhikevich

De acuerdo al estudio realizado y comentado en el capítulo 3 sección 3.7.1, la arquitectura para la SNN, se formó como sigue (Figura 4.5):

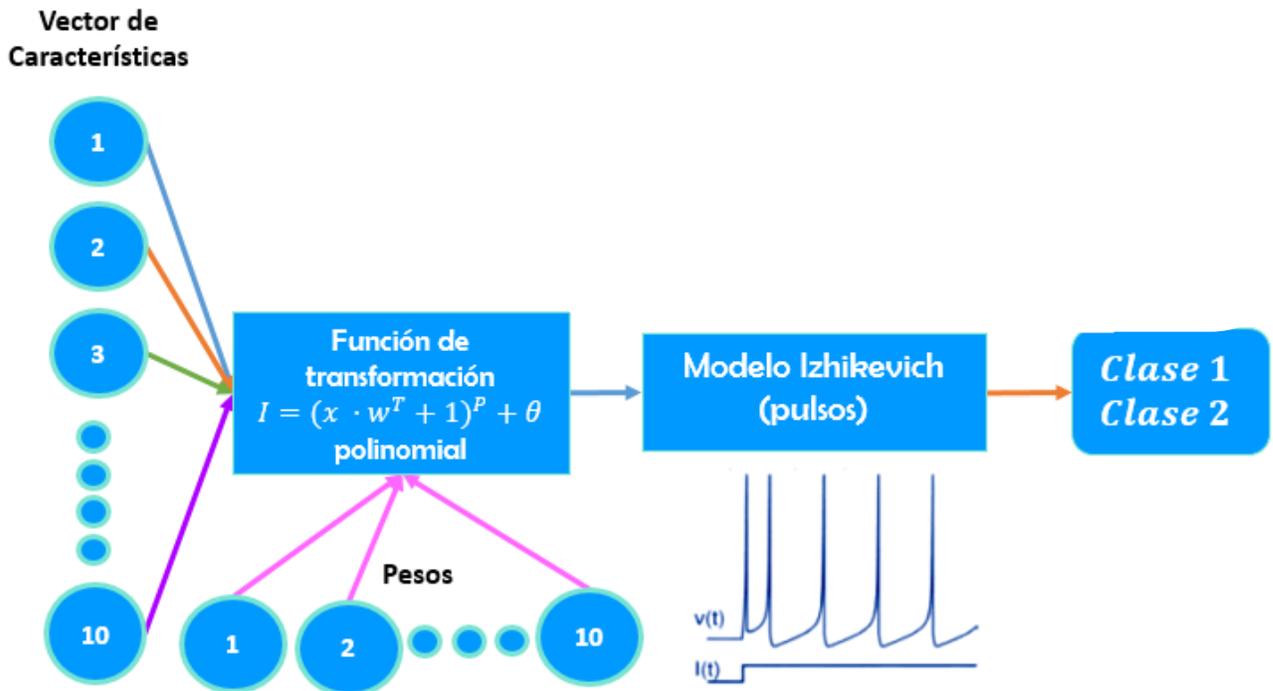


Figura 4.5 Arquitectura del modelo de Izhikevich mediante el cual son analizadas entradas de datos.

Tabla 4.5 Parámetros de entrenamiento de una SNN en la clasificación de imágenes cerebrales.

SNN			
Elementos del Vector de Características	10	Regular Spike	
		Parámetro	Valor
Conjunto de datos	N= 50, 80, 85, 90, u 92	C	100
		k	0.7
		v_r	-60
		v_t	-40
Nodos de salida	1	a	0.03
Tasa de aprendizaje	0.02, 0.05	b	-2
Tolerancia	0.75	c	-50
No. de pulsos	1,000	d	100

- 1) Nodos de entrada. En este caso la corriente de la entrada para este tipo de ANN, es dada por el resultado de aplicar la función de transformación seleccionada al vector de características, en conjunto con sus pesos.
- 2) Nodos de capa oculta. La mayoría de los algoritmos utilizados en las SNNs representan la información de salida mediante pulsos, para ello se requiere del cálculo de las corrientes de entrada con respecto al tiempo [Matadamas, 2014], por lo que el contenido de la capa oculta está dado por una variable contadora de pulsos, de las neuronas de la capa anterior inmediata en forma de vector, en conjunto con un vector de parámetros único para la función de transformación perteneciente cada neurona de la capa [Matadamas, 2014].
- 3) Nodo de salida. Clases (sano o enfermo).
- 4) Número de pulsos. Se tomó como parámetro 1,000 *spikes*, simulando el número máximo de pulsos que genera el modelo Izhikevich durante un segundo.
- 5) Función de transformación: polinomial (ecuación 3.5).

Tabla 4.6 Algoritmo propuesto de una SNN

1	Leer la información de los archivos *.txt
2	Se divide la información de acuerdo al porcentaje de entrenamiento y evaluación
Inicialización	
3	Se inician los pesos aleatoriamente con distribución uniforme
4	Se generan pulsos iniciales para los elementos de entrenamiento
5	Definir los representantes de la clase
Entrenamiento:	
6	For épocas=1 hasta límite de épocas
7	For cada x en el conjunto de entrenamiento
8	Calcular I mediante la fórmula $I = (\sum_{k=1}^n w_k x_k + 1)^2$
9	Calcular los pulsos y_i aplicando el modelo Izhikevich, mediante las fórmulas 3.2,3.3 y 3.4
10	For cada w_i
11	Calcular Δw_i mediante la fórmula
	$\Delta w_i = -\alpha x_i (y - y') \left(\sum_{k=1}^n w_k x_k + 1 \right)$
12	Actualizar w_i con la fórmula $w_i = w_i + \Delta w_i$
13	End for w_i
14	End for x
15	For cada x en el conjunto de entrenamiento
16	Calcular I mediante la fórmula $I = (x \cdot w' + 1)^2 + \theta$
17	Calcular los pulsos y_i mediante las fórmulas 3.2, 3.3 y 3.4
18	Asignar clases $Y \in [0,1]$, en este caso $Y = 2$ (<i>enfema</i>) y $Y = 5$ (<i>sana</i>).
19	End for x
20	Calcular <i>accuracy</i>
21	If <i>accuracy</i> ha alcanzado el valor deseado
22	Detener algoritmo
23	End if
24	Calcular la norma del gradiente
25	Calcular error absoluto
26	End for épocas

4.8 Evaluación usando la técnica de validación cruzada

Para ambas ANNs se utilizó la técnica de validación cruzada sobre el conjunto de datos de 111 imágenes cerebrales, para ello se realizaron 10 experimentos con distintos *folds* (divididos como en la Tabla 4.2), se optó por trabajar con una validación cruzada para el aprendizaje de 90%, 80%, 75% y 50% y el resto de los datos para

clasificación, esta separación se hizo de manera aleatoria para cada una de las repeticiones del experimento.

Una métrica muy utilizada, tanto en una clasificación binaria como en la multiclase es el *Accuracy* (ecuación 4.6), la cual ayuda en la evaluación del porcentaje de casos correctamente clasificados, representada como la siguiente de matriz de confusión:

Tabla 4.7 Matriz de confusión para el cálculo del *accuracy*.

		Valor en la realidad	
		Positivo	Negativo
Predicción	Positivo	Verdaderos Positivos #TP	Falsos Positivos #FN
	Negativo	Falsos Negativos #FP	Verdaderos Negativos #TN

Cuya fórmula es:

$$Accuracy = \frac{\#TP + \#TN}{\#TP + \#TN + \#FP + \#FN} = \% \quad (4.6)$$

Donde:

TP: Verdaderos Positivos, *FP*: Falsos Positivos, *TN*: Verdaderos Negativos, *FN*: Falsos Negativos

4.9 Discusión

Existen diferentes tipos de imágenes cerebrales que se pueden clasificar mediante las *ANN*, con resultados favorables. De igual manera, hay un sin número de técnicas que pueden aplicarse en el preprocesamiento de imágenes, sin embargo, en este trabajo se utiliza el filtrado, por su estudio frecuente.

Además, el modelo de Izhikevich, aquí estudiado cuenta con diferentes simulaciones del potencial de acción como la *Regular Spike* (cuyos parámetros son los más frecuentes en los mamíferos).

En el siguiente capítulo se muestra la aplicación de la *SNN* en la clasificación de imágenes cerebrales.

CAPÍTULO 5. EXPERIMENTACIÓN Y RESULTADOS

Se exponen los resultados de los casos presentados en el capítulo 4, además del énfasis de las pruebas de validación realizadas tanto para la *ANN MLP* como de la *SNN*, realizadas sobre las bases de datos de imágenes *MRI* cerebrales; los resultados de la variación en los parámetros de θ y α , analizados en el entrenamiento y reconocimiento de las *ANNs*. Por último, se realiza la discusión de la comparación de los resultados obtenidos de las *ANNs*.

5.1 Implementación en software

Se desarrolló una interfaz en el *guide* de Matlab, en la cual se pueden aplicar los filtros a distintas imágenes para generar vectores de características, en Simulink se representaron de manera gráfica. También mediante programas en C++, se desarrollaron algunas funciones, así como la programación de la arquitectura de cada una de las *ANNs*, observando con mayor interés los resultados de la *SNN*.

5.2 Comparación de resultados de preprocesamiento manual y automática

Se consideraron imágenes en escala de grises correspondientes a cerebros sanos y otros con anomalías, algunas imágenes contenían artefactos fuera del área craneal, por lo que primeramente se experimentó limpiando la imagen de forma manual. Para el segundo experimento, mediante un programa desarrollado en Matlab usando la técnica *skull stripping*, de la investigación de [Shaswati, 2015] se eliminaron esos mismos artefactos. Se obtuvo que los resultados obtenidos del preprocesamiento usando la técnica *skull stripping* dependía de parámetros adaptativos en función del conocimiento de la distribución de intensidad en las imágenes de *MRI*. (Anexo B del CD)

5.3 Pruebas y filtrado de imágenes

Después de aplicar los filtros y realizar un promedio de los pixeles a cada una de las imágenes, el resultado se almacenó en una base de datos, para posteriormente graficar una comparación entre los filtros (Anexo F del CD), con el fin de analizar el comportamiento de cada uno de ellos, en especial para corroborar si entre ellos existía

algún traslape (se generan valores iguales entre cerebros sanos y enfermos), que impidiera realizar un reconocimiento favorable en la etapa de aprendizaje de las redes neuronales. Se observó que:

- Los *filtros de suavizado* distinguen mejor sólo a los cerebros enfermos o con anomalías.
- Los *filtros de detección de bordes* concuerdan en sus resultados tanto para distinguir a los cerebros enfermos de los sanos.
- Los *filtros de restauración de imágenes* realzaron detalles de contraste en niveles de grises de la imagen.
- Los *filtros de operaciones morfológicas* reportaron resultados con traslape, aunque este traslape se ubicaba en los patrones del mismo tipo.
- En los *filtros de segmentación*, el filtro Laplaciano realizó una separación más exacta, ya que a los cerebros sanos los clasificaba con un valor muy cercano al uno.

De acuerdo a la experimentación, el filtro que logra distinguir más favorablemente entre cerebros sanos y cerebros enfermos es el Laplaciano, sin embargo, se deja que la ANN decida cuál es el filtro que considera el mejor, ya que según su análisis de los pesos asociados con las entradas dicen cuáles son los filtros más correlacionados con la clase.

5.4 Diseño de la SNN

Los pulsos de salida deseados en la SNN, se asignaron de acuerdo a la clase a la que pertenecían las imágenes, para las sanas se les determinó “2 *spikes*”, para imágenes con *BSD* “5 *spikes*”, además se experimentó con las tasas de aprendizaje de 0.02 y 0.05 y para el valor de θ (que representa el flujo de potencial de acción), se tomaron los valores de 35 y 40.

5.5 Aprendizaje y reconocimiento de las ANNs MLP y SNN

Siendo la *MLP* una de las ANN más frecuentes en la aplicación de aprendizaje y clasificación de imágenes [Dridi, 2016], se comparó con la *SNN*, usando como bases

de datos el conjunto de vectores correspondientes a cada una de las imágenes (Anexo E del CD), de esto se obtuvo que:

Para la etapa de aprendizaje o entrenamiento:

1. Se usó el mismo conjunto de datos, a los que se les aplicó un *fold* de 10 en todos los experimentos, teniendo en cuenta que para la *MLP* el entrenamiento se detiene cuando se llega a un error mínimo.
2. Los pesos iniciales se iniciaron en un rango de [0;1].
3. Se hicieron converger a ambas *ANNs* con 1,000 épocas, sin embargo, para la *ANN MLP* se tuvo que modificar este valor a 1,5000.
4. Las tasas de aprendizaje se iniciaron en 0.02 y 0.05
5. En la asignación de patrones en la *MLP*, al valor de la clase “sano” se le asignó un 1, mientras que la clase “enfermo” un 0.
6. En los patrones de la *SNN*, las clases se asignaron de acuerdo a los pulsos generados, lo que dio un valor de “2” para la clase “sano” y un valor de 5 para la clase “enfermo”.
7. Como la *SNN* necesita un valor que represente el flujo del potencial de acción, éste se estudió a partir de los valores 35 y 45 (activación de la neurona).

Para la etapa de reconocimiento:

1. Se usaron diferentes porcentajes respecto al *accuracy* o error mínimo a calcular.
2. En el caso de la *SNN*, los valores asignados para el umbral de activación de la neurona fueron 35 y 40.

Como resultado, la *SNN* obtuvo porcentajes más altos que la *MLP* en la etapa de aprendizaje y reconocimiento, cuando el valor de $\alpha = 0.02$ (Tabla 5.1).

No obstante, cuando $\alpha = 0.05$ (Tabla 5.2) la *SNN*, los resultados de esta red, no distaban mucho del 50%.

Tabla 5.1 Resultados de la SNN cuando $\alpha = 0.02$

$\alpha = 0.02$				
FOLD	$\theta = 35$		$\theta = 40$	
	Aprendizaje	Reconocimiento	Aprendizaje	Reconocimiento
1	88.888893	80	91.111115	80
2	84.444443	60.000004	91.111115	60.000004
3	84.444443	100	91.111115	100
4	93.333336	40	95.555557	60.000004
5	88.888893	60.000004	91.111115	60.000004
6	88.888893	60.000004	91.111115	80
7	86.666664	80	91.111115	100
8	88.888893	0	91.111115	80
9	88.888893	40	91.111115	40
10	86.666664	40	91.111115	60
promedio	88%	56%	91.55%	72%

Tabla 5.2. Resultados de la SNN cuando $\alpha = 0.05$

$\alpha = 0.05$				
FOLD	$\theta = 35$		$\theta = 40$	
	Aprendizaje	Reconocimiento	Aprendizaje	Reconocimiento
1	51.111115	80	51.111115	80
2	55.555557	40	55.555557	40
3	55.555557	40	55.555557	40
4	55.555557	40	55.555557	40
5	53.333336	60.000004	53.333336	60
6	53.333336	60.000004	53.333336	60
7	55.555557	40	55.555557	40
8	53.333336	60.000004	53.333336	60.000004
9	57.777779	20	57.777779	20
10	48.888889	100	48.888889	100
promedio	54%	54%	54%	54%

La ANN MLP, arrojó los siguientes porcentajes en la etapa de aprendizaje y reconocimiento:

Tabla 5.3 Resultados de la MLP cuando $\alpha = 0.02$ y $\alpha = 0.05$

FOLD	$\alpha = 0.02$		$\alpha = 0.05$	
	Aprendizaje	Reconocimiento	Aprendizaje	Reconocimiento
1	90.01	92	92.01	51.04
2	90.81	92	92.00	50
3	80.34	82	82.01	50.55
4	95.88	92	92.00	20
5	92.01	98	98.00	47.47
6	90.00	84	84.03	51.09
7	90.88	98	98.00	51.25
8	80.34	92	92.01	51.04
9	95.88	96	96.01	50
10	92.01	90	90.00	47.37
promedio	89.816	91.6	91.607	50.00078

5.6 Clasificación y ajuste de parámetros por porcentaje de datos

Como otra experimentación se buscó ajustar los parámetros de la red por medio de un conjunto de datos de entrenamiento, un número límite de épocas y un porcentaje logrado de *accuracy*, al aplicarse la técnica de validación cruzada, se utiliza una partición distinta en cada experimento, de acuerdo al porcentaje de entrenamiento y clasificación dado por el usuario. La función elegida para cada neurona fue la función polinomial.

5.7 Análisis de la salida de la aplicación de SNN.

Los resultados generados en la experimentación de la SNN se encuentran especificados en el Anexo H del CD, dicho análisis arrojó los siguientes datos:

1.- En la variación de $\theta = 35$ y $\theta = 45$, se optó por registrar los valores de $\theta = 55$, $\theta = 56$ y $\theta = 57$, ya que en estos valores representaban la actividad más alta de la neurona.

2.- El uso de los porcentajes 90%, 85%, 80% y 75% para seleccionar un subconjunto de datos, tuvo el propósito de indagar el hecho de que una SNN clasifica mejor con muchos datos en la etapa de aprendizaje, o si con pocos datos la SNN tendría menos errores en la etapa de reconocimiento.

▪ **Cuando $\alpha=0.02$ y $\theta=35$**

El primer experimento consistió en agregar una tasa de aprendizaje de $\alpha= 0.02$, empezando a evaluar a partir de $\theta = 35$, debido a que en un análisis previo se verificó que la neurona empezaba a desactivarse (decaía el pulso) después de que el valor $\theta = 57$, obteniéndose los datos de la Tabla 5.4.

Tabla 5.4 Resultados cuando $\alpha = 0.02$ y $\theta = 35$ en las etapas de aprendizaje y reconocimiento.

Alpha=0.02	APRENDIZAJE					RECONOCIMIENTO						
	Sanos	23	40	37	48	50	23	40	37	48	50	
	Enfermos	27	40	48	42	42	27	40	48	42	42	
Porcentaje de instancias de entrenamiento	CASOS	50	80	85	90	92	50	80	85	90	92	
90%	Theta	55	97.78	94.44	94.81	87.65	86.75	80	100	75	77.78	77.78
		56	100	95.83	94.81	88.89	86.75	60	100	62.5	77.78	77.78
		57	97.78	95.83	94.81	87.65	87.95	60	100	75	77.78	77.78
85%	Theta	55	97.67	95.59	94.44	87.01	85.9	85.71	100	76.92	84.62	85.71
		56	100	95.59	94.44	87.01	85.9	71.43	100	84.62	84.62	85.71
		57	100	97.06	95.83	87.01	87.18	57.14	100	84.62	76.92	78.57
80%	Theta	55	97.5	95.31	95.59	87.5	87.84	90	100	76.47	83.33	83.33
		56	100	95.31	95.59	88.89	90.54	90	100	76.47	83.33	83.33
		57	100	95.31	97.06	87.5	89.19	70	100	82.35	77.78	88.89
75%	Theta	55	84.21	96.67	95.31	86.36	85.51	66.67	100	85.71	86.36	82.61
		56	100	95	95.31	88.24	91.3	83.33	100	85.71	86.36	86.96
		57	97.37	95	96.88	86.76	88.41	75	100	80.95	81.82	82.61

Dentro de la Tabla 5.4, los valores resaltados en color verde especifican los mejores parámetros que la neurona utiliza en el aprendizaje y reconocimiento, mientras que los resaltados en color rojo los más bajos; para tener una mejor apreciación a continuación se analiza su comportamiento de acuerdo al número de datos.

Cuando se utilizaba el **90%** de los datos seleccionados del conjunto total de datos, se obtuvieron los siguientes resultados:

Aprendizaje alto: 50 casos

Reconocimiento alto: 80 casos

Aprendizaje bajo: 92 casos

Reconocimiento bajo: 50 casos

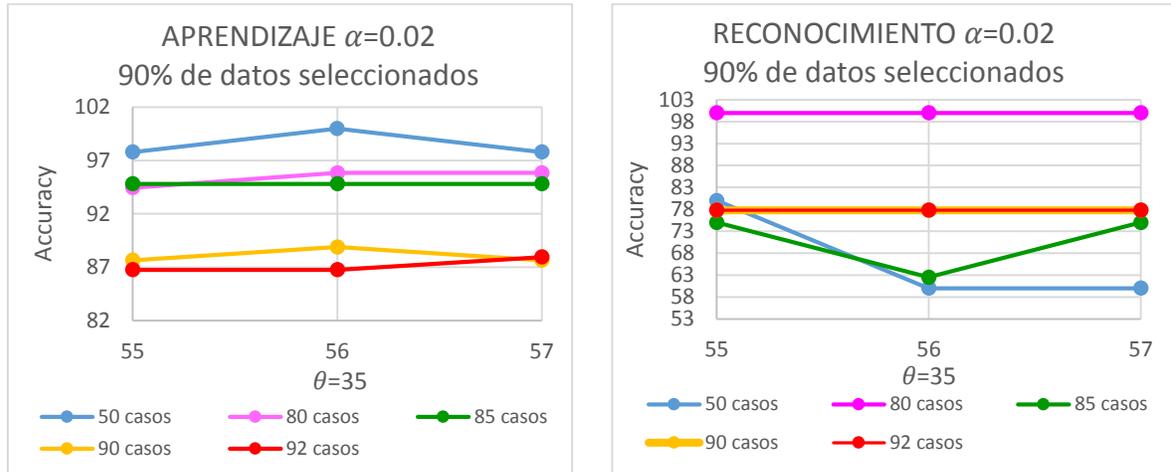


Figura 5.1 Accuracy correspondiente al aprendizaje y reconocimiento del 90% de datos seleccionados.

En el experimento del **85%** de los datos seleccionados, se obtuvo:

Aprendizaje alto: 50 casos

Reconocimiento alto: 80 casos

Aprendizaje bajo: 92 casos

Reconocimiento bajo: 50 casos

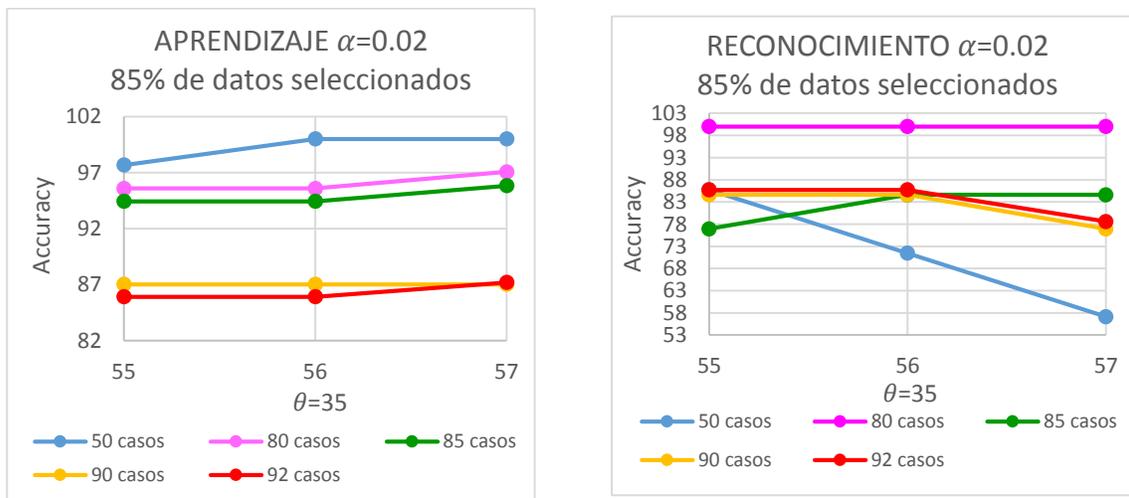


Figura 5.2 Accuracy correspondiente al aprendizaje y reconocimiento del 85% de datos seleccionados.

En el caso de **80%** de datos seleccionados del conjunto total de datos, se obtuvo:

Aprendizaje alto: 50 casos

Reconocimiento alto: 80 casos

Aprendizaje bajo: 90 casos

Reconocimiento bajo: 85 casos

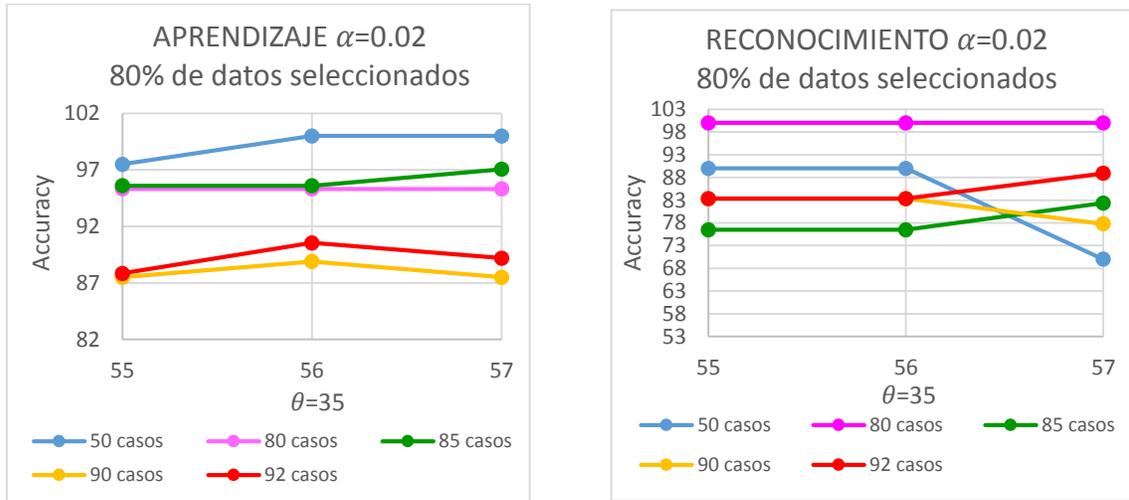


Figura 5.3 Accuracy correspondiente al aprendizaje y reconocimiento del 80% de datos seleccionados.

Cuando se utilizaba el **75%** de los datos seleccionados del conjunto total, se obtuvo:

Aprendizaje alto: 50 casos

Reconocimiento alto: 80 casos

Aprendizaje bajo: 90 casos

Reconocimiento bajo: 50 casos

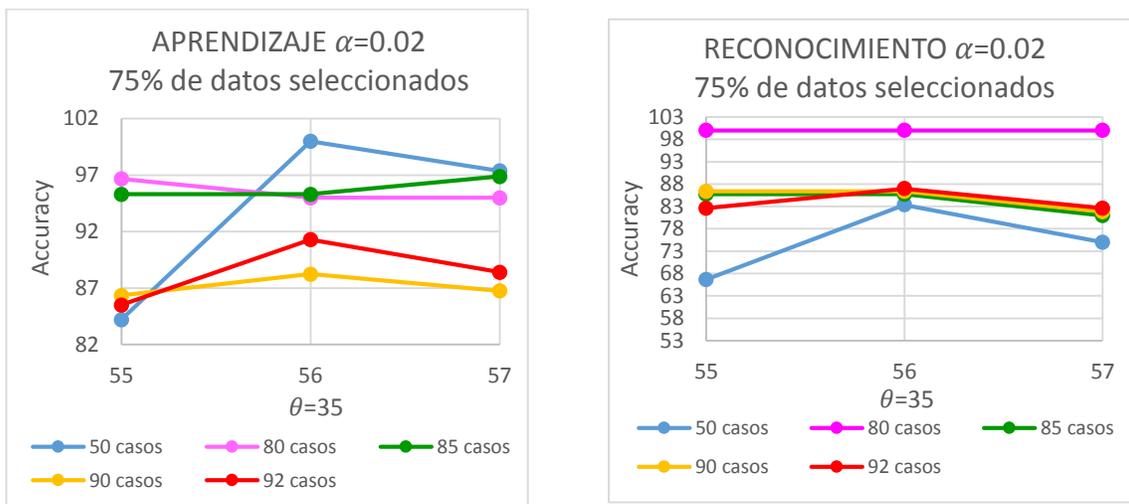


Figura 5.4 Accuracy correspondiente al aprendizaje y reconocimiento del 75% de datos seleccionados.

Visto de otra manera, cuando se analizan los resultados a partir del conjunto total de datos, en el experimento de los **50 casos**, se observó:

Aprendizaje alto: 85%	Reconocimiento alto: 80%
Aprendizaje bajo: 75%	Reconocimiento bajo: 90%

Es decir, se observa que, aunque el *accuracy* en la etapa del aprendizaje era alto (teniendo pocos datos), el *accuracy* en la etapa de la clasificación nunca lo superaba. (Figura 5.5).

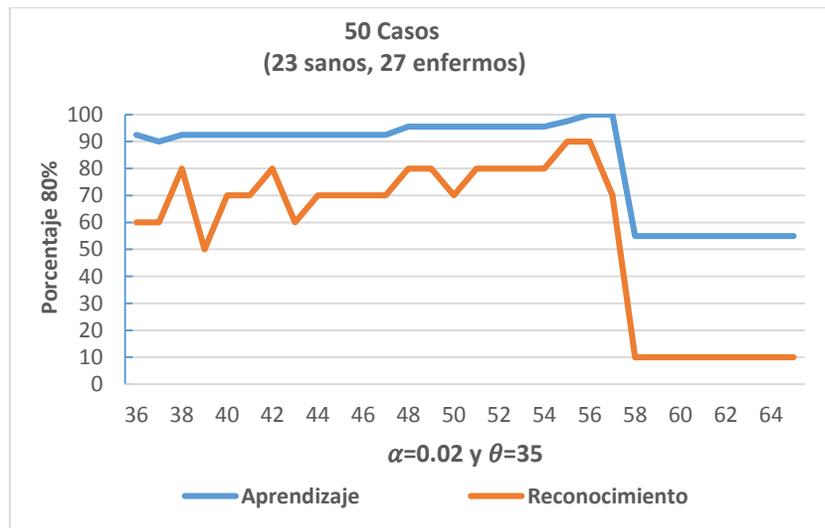


Figura 5.5 *Accuracy* para el 80% de instancias seleccionadas de un total de 50 imágenes.

En el experimento de los **80 casos**, se observó:

Aprendizaje alto: 85%	Reconocimiento alto: Todos
Aprendizaje bajo: 90%	Reconocimiento bajo: Ninguno

Lo que indica, que la neurona de la SNN tuvo un comportamiento favorable en ambas etapas, recalándose que tanto para la etapa del aprendizaje como para la etapa de reconocimiento se contó con un conjunto de datos formado por la misma cantidad de imágenes pertenecientes tanto de una misma clase como de otra.

Además, el porcentaje de aprendizaje *accuracy* más bajo fue cercano al 95% en todos los casos, ésta la clasificación fue la más favorable (Figura 5.6).

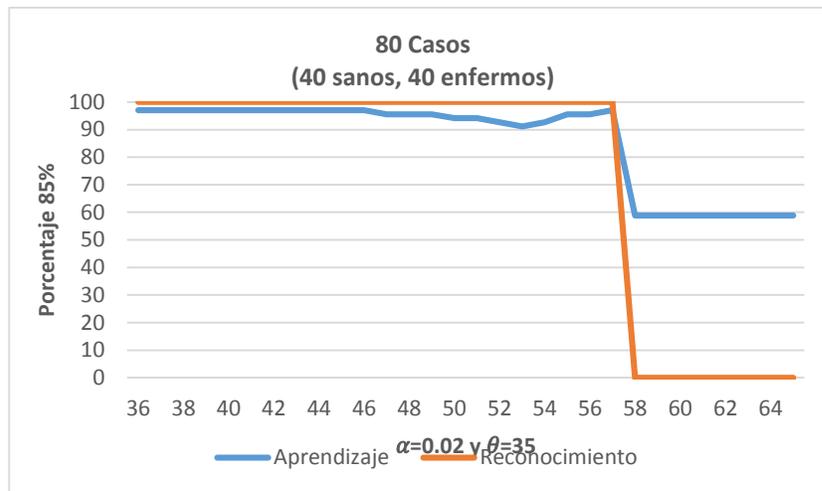


Figura 5.6 Accuracy para el 85% de instancias seleccionadas de un total de 80 imágenes.

En el experimento de los **85 casos**, se observó que:

Aprendizaje alto: 80%

Reconocimiento alto: 75%(Figura 5.7).

Aprendizaje bajo: 90%

Reconocimiento bajo: 90%

Aquí también el reconocimiento no superó el accuracy de la etapa de aprendizaje.

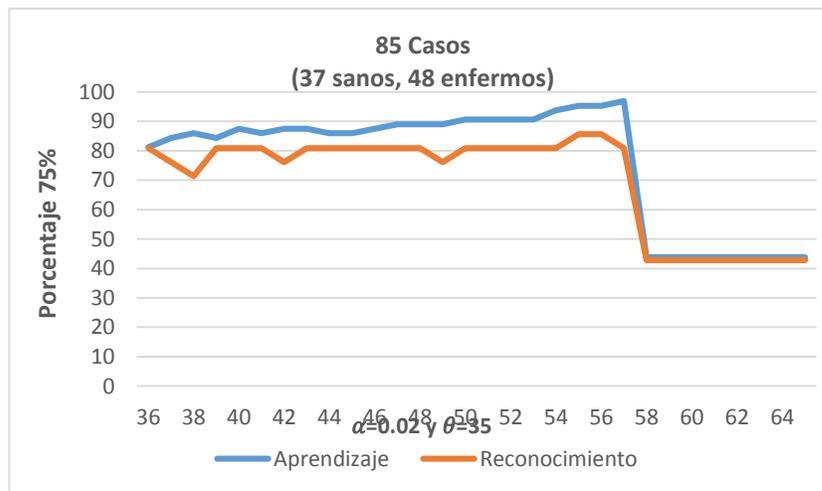


Figura 5.7 Accuracy para el 75% de datos seleccionados de un total de 85 imágenes.

En el experimento de los **90 casos**, se observó que:

Aprendizaje alto: 90%

Reconocimiento alto: 75% (Figura 5.5).

Aprendizaje bajo: 75%

Reconocimiento bajo: 90%

En esta prueba hubo mucho traslape en todas las muestras del *accuracy*, por lo que se puede considerar el caso menos certero.

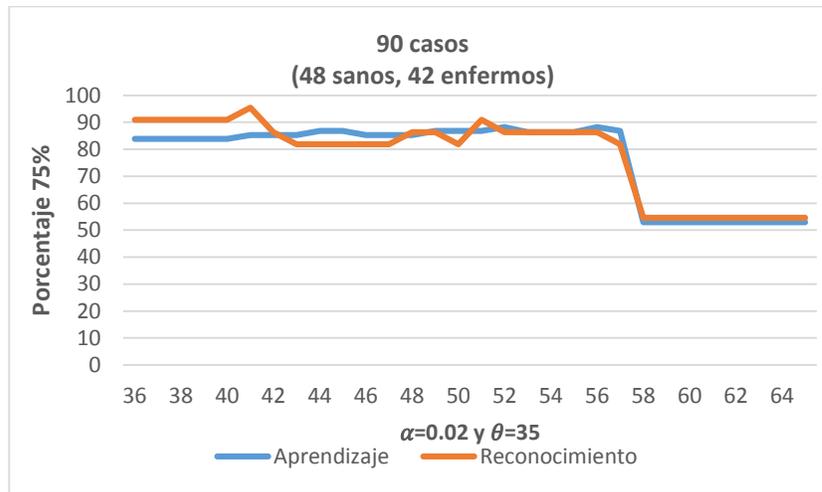


Figura 5.8 *Accuracy* para el 75% de instancias seleccionadas de un total de 90 imágenes.

En el experimento de los **92 casos**, se observó que

Aprendizaje alto: 80%

Reconocimiento alto: 80%

Aprendizaje bajo: 85%

Reconocimiento bajo: 90%

En este caso, el reconocimiento superó el *accuracy* del aprendizaje, al alimentar la neurona con más imágenes (Figura 5.5).

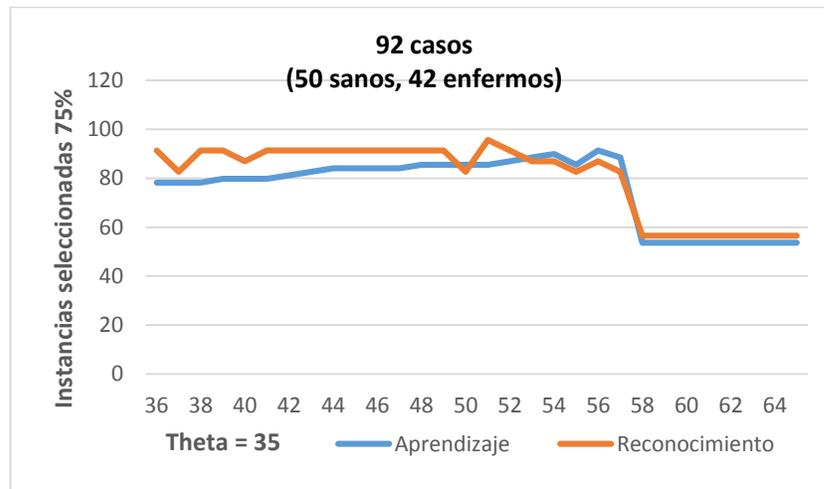


Figura 5.9 *Accuracy* para el 75% de instancias seleccionadas de un total de 92 imágenes.

▪ **Cuando $\alpha=0.05$ y $\theta =40$**

En la siguiente experimentación se consideró una tasa de aprendizaje de $\alpha= 0.05$, es decir se hizo más grande el valor de α con el fin de estudiar si el valor del error aumenta y si el número de patrones correctamente clasificados disminuye, empezando con un valor de $\theta = 40$, la siguiente Tabla muestra los resultados obtenidos:

Tabla 5.5 Resultados cuando $\alpha = 0.05$ y $\theta = 40$ en las etapas de aprendizaje y reconocimiento.

alpha=0.05	APRENDIZAJE						RECONOCIMIENTO					
	Sanos	23	40	37	48	50	23	40	37	48	50	
	Enfermos	27	40	48	42	42	27	40	48	42	42	
	Casos	50	80	85	90	92	50	80	85	90	92	
90%	Theta	55	97.78	95.83	94.81	87.65	90.36	80	87.5	62.5	77.78	88.89
		56	100	95.83	96.1	90.12	91.57	60	87.5	75	77.78	88.89
		57	95.56	93.06	94.81	88.89	89.16	60	100	75	77.78	77.78
85%		55	97.67	94.12	94.44	87.01	89.74	85.71	91.67	76.92	84.62	92.86
		56	100	97.06	95.83	88.31	93.54	71.43	91.67	84.62	84.62	78.57
		57	95.35	92.65	94.44	88.31	88.46	71.43	100	84.62	76.92	92.86
80%		55	100	93.75	95.59	90.28	93.24	90	93.75	76.47	83.33	83.33
		56	100	95.31	97.06	91.67	93.24	80	87.5	82.35	88.89	83.33
		57	97.5	93.75	97.06	88.89	89.19	80	81.25	76.47	83.33	88.89
75%		55	97.37	91.67	95.31	92.65	94.2	83.33	90	85.71	77.27	82.61
		56	100	96.67	96.88	91.18	92.75	83.33	80	85.71	72.73	86.96
		57	94.74	91.67	95.31	88.24	88.41	75	100	85.71	77.27	82.61

Los números en color verde registran el mejor comportamiento de la neurona tanto de la etapa de aprendizaje como de reconocimiento, dependiendo del número de casos total de casos con los que se alimentó a la SNN, mientras que los números en color rojo registran los resultados más bajos.

Cuando se utilizaba el **90%** de los datos seleccionados del conjunto total de datos, se obtuvieron los siguientes resultados:

Aprendizaje alto: 50 casos

Reconocimiento alto: 80 casos

Aprendizaje bajo: 90 casos

Reconocimiento bajo: 50 casos

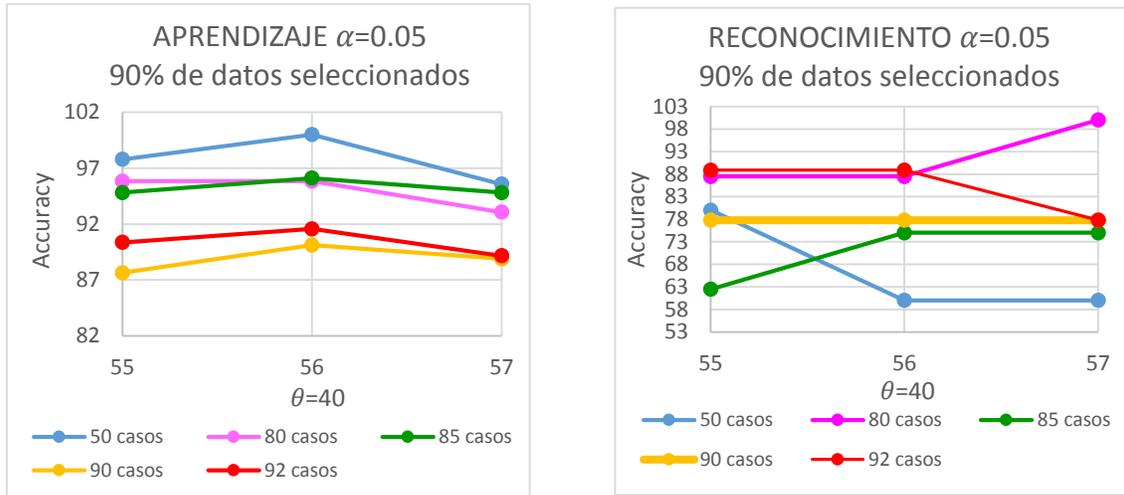


Figura 5.10 Accuracy correspondiente al aprendizaje y reconocimiento del 90% de datos seleccionados.

En el experimento del **85%** de los datos seleccionados, se obtuvo:

Aprendizaje alto: 50 casos

Reconocimiento alto: 80 casos

Aprendizaje bajo: 90 casos

Reconocimiento bajo: 50 casos

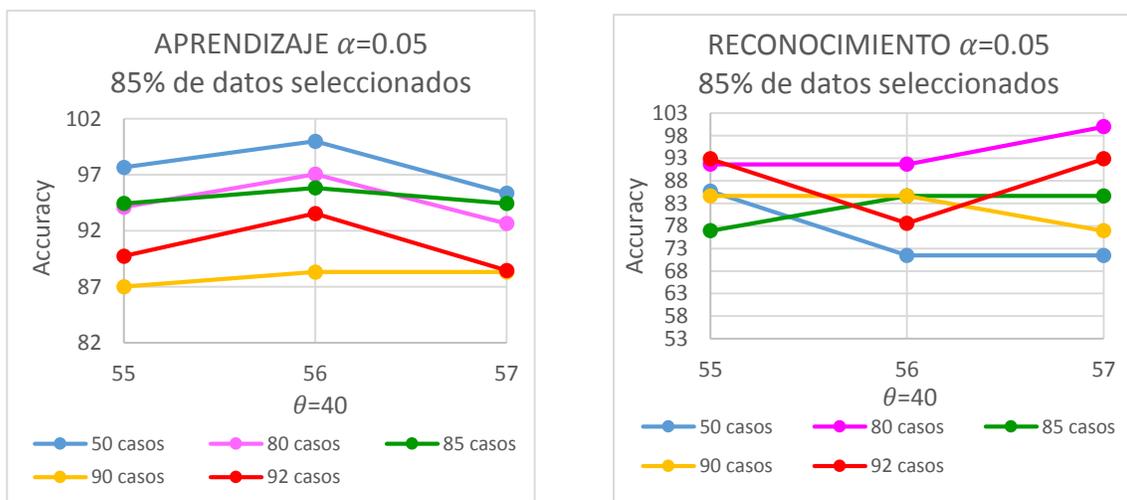


Figura 5.11 Accuracy correspondiente al aprendizaje y reconocimiento del 85% de datos seleccionados.

En el caso de **80%** de datos seleccionados del conjunto total de datos, se obtuvo:

Aprendizaje alto: 50 casos

Reconocimiento alto: 80 casos

Aprendizaje bajo: 90 casos

Reconocimiento bajo: 85 casos

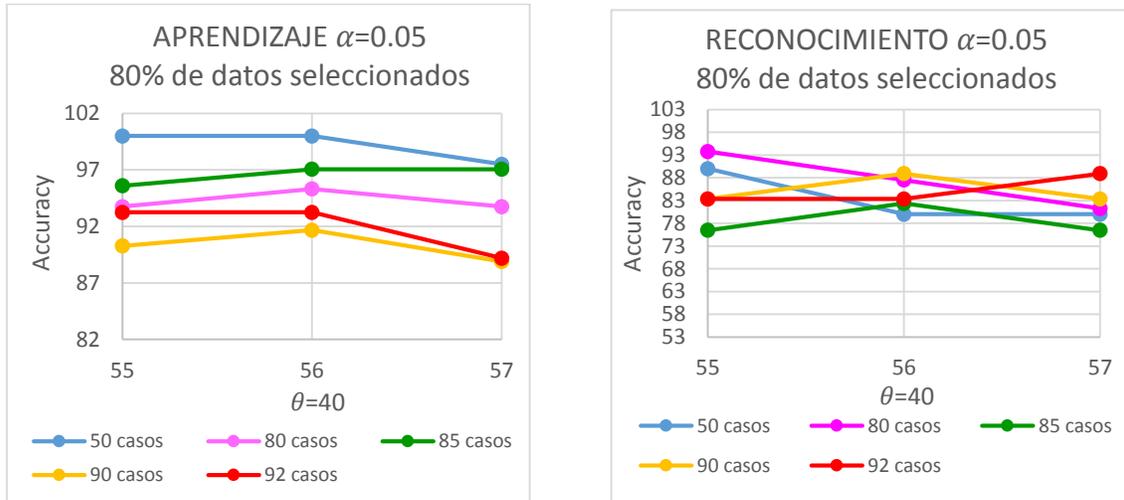


Figura 5.12 Accuracy correspondiente al aprendizaje y reconocimiento del 80% de datos seleccionados.

Con el **75%** de los datos seleccionados del conjunto total, se obtuvo:

Aprendizaje alto: 50 casos

Reconocimiento alto: 80 casos

Aprendizaje bajo: 90 casos

Reconocimiento bajo: 90 casos

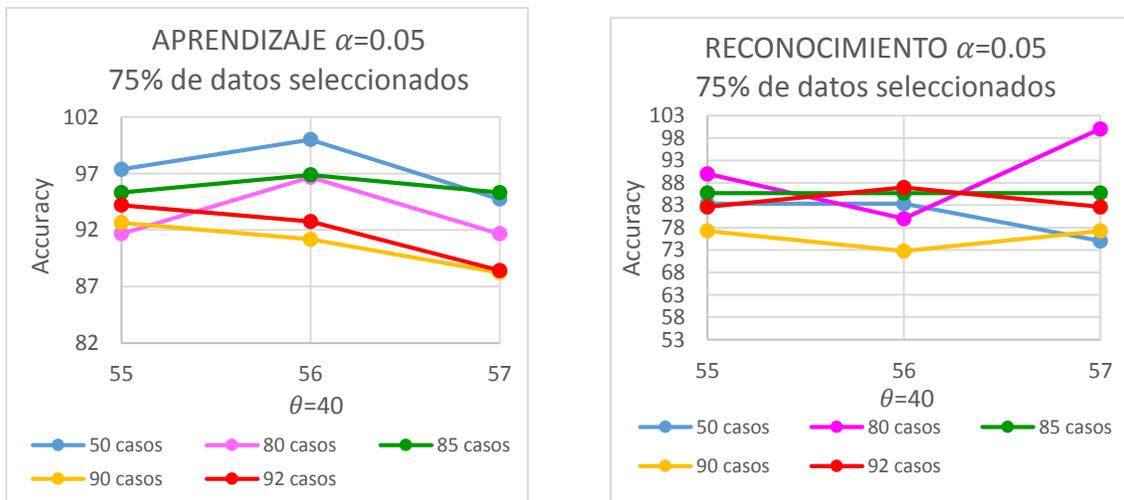


Figura 5.13 Accuracy correspondiente al aprendizaje y reconocimiento del 75% de datos seleccionados.

Aunque gráficamente pareciera que la SNN se comporta de la misma manera, incluso cambiando la tasa de aprendizaje a 0.05, al analizar los resultados a partir del conjunto de datos totales, se observó que:

Cuando se analizan los resultados a partir del conjunto total de datos, en el experimento de los **50 casos**, resultó que aún cuando se lograba un aprendizaje del 100%, el reconocimiento era bajo, no obstante, la clasificación era muy favorable, el mejor comportamiento se obtuvo con el 80% de datos de entrenamiento, cabe destacar que se entrenaron más cerebros enfermos que sanos (Figura 5.14).

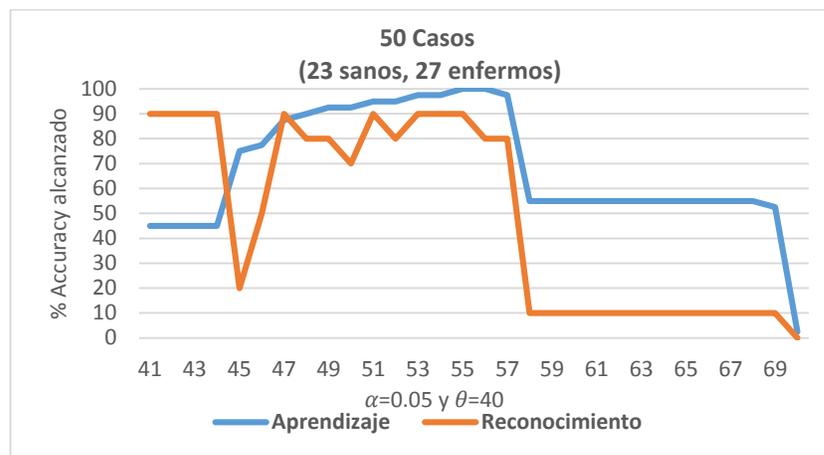


Figura 5.14 Accuracy para el 80% de instancias seleccionadas de un total de 50 imágenes.

En el experimento con un total de **80 casos**, seleccionando el 85% y 90% de datos, se generaba un comportamiento alto en el aprendizaje (accuracy de 97%), y el 100% (accuracy) de reconocimiento de los datos (Figura 5.15).

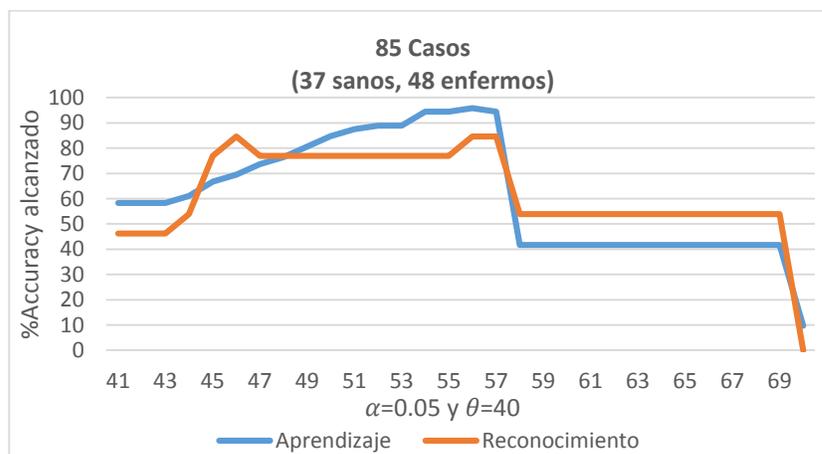


Figura 5.15 Accuracy para el 85% de datos seleccionados de un total de 80 imágenes.

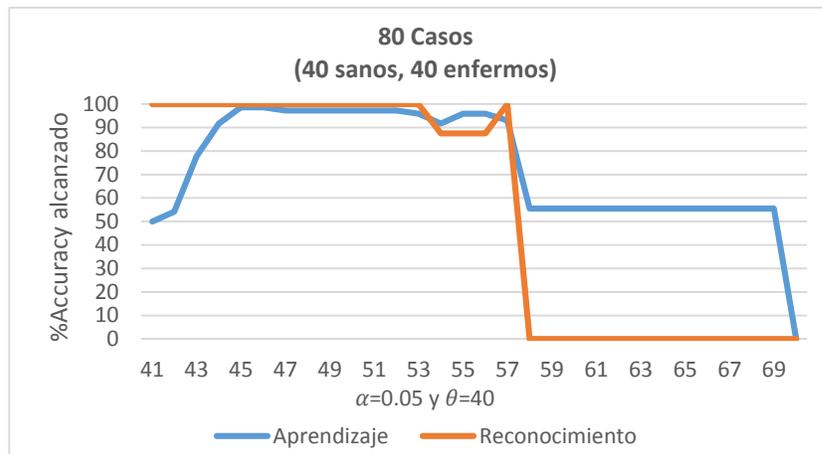


Figura 5.16 Accuracy para el 90% de datos seleccionados de un total de 80 imágenes.

En el experimento con 85 **casos**, los datos con una mayor respuesta en el aprendizaje y reconocimiento se generaron con un 80% y 75% de los datos entrenados (Figura 5.17), sin embargo se observa que el aprendizaje nunca es superado por el reconocimiento.

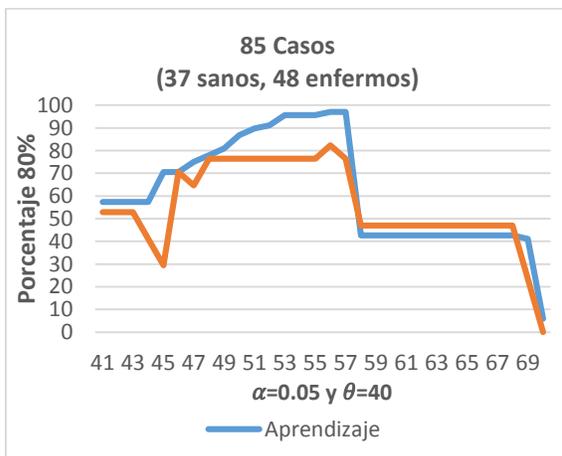


Figura 5.17 Accuracy para el 80% de datos seleccionados de un total de 85 imágenes.

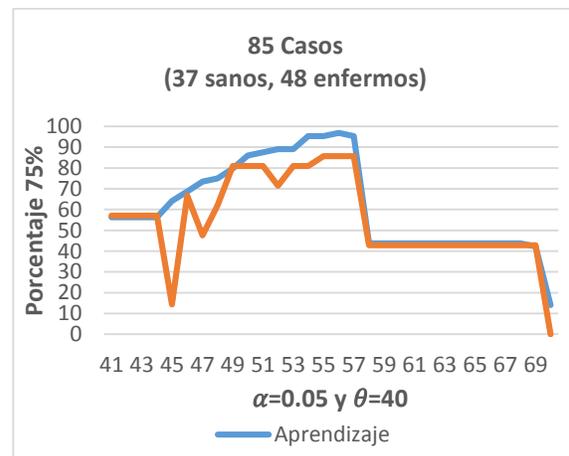


Figura 5.18 Accuracy para el 75% de datos seleccionados de un total de 85 imágenes.

Con un total de **90 casos**, se observó que el porcentaje de *accuracy* generado para el aprendizaje oscilaba entre el 87% y 92%, el reconocimiento estaba entre el 77% al 86%, siendo el número de datos seleccionados del 90% y 80% respectivamente (Figura 5.19).

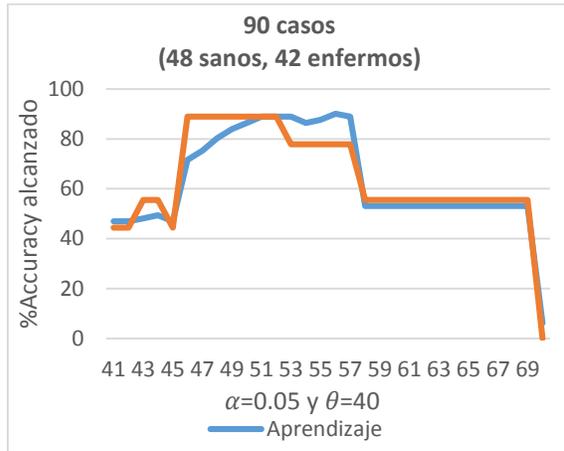


Figura 5.19 *Accuracy* para el 90% de datos seleccionados de un total de 90 imágenes.

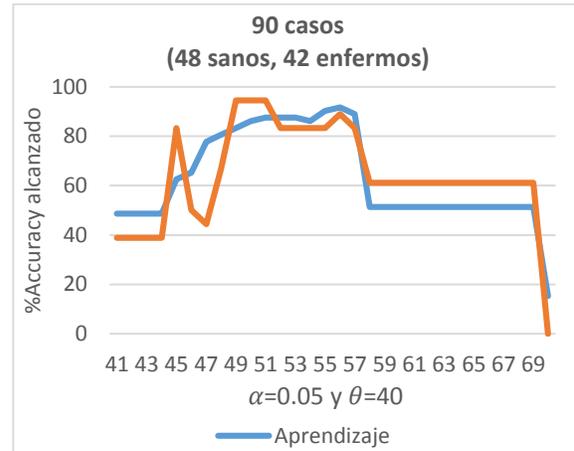


Figura 5.20 *Accuracy* para el 80% de datos seleccionados de un total de 90 imágenes.

En el experimento de los **92 casos**, se observó que entre más casos tenía la neurona, y el *accuracy* era mayor a 80%, se generaba el mejor aprendizaje y reconocimiento (Figura 5.10).

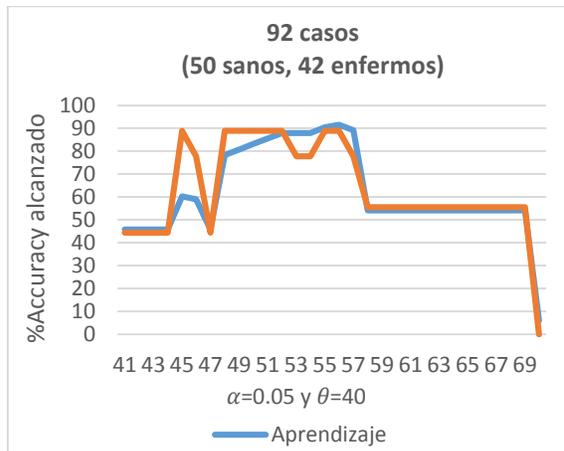


Figura 5.21 *Accuracy* para el 90% de datos seleccionados de un total de 92 imágenes.

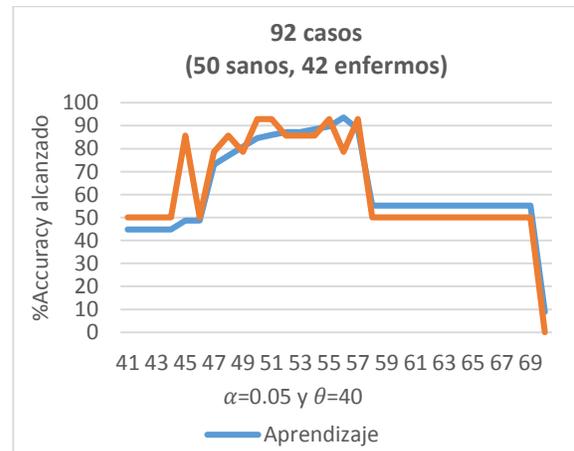


Figura 5.22 *Accuracy* para el 80% de datos seleccionados de un total de 92 imágenes.

5.8 Discusión

La experimentación realizada en C++ fue comparada con los resultados obtenidos en Matlab. En la etapa de preprocesamiento se concluye que la técnica *skull stripping* es una buena opción para optimizar zonas de interés de forma automática, puesto que se generaron los mismos resultados que cuando se realizaba la limpieza en las imágenes de manera manual. Dentro de las pruebas en la generación de vectores de características se obtuvo de un análisis previo la siguiente Tabla:

Tabla 5.6 Análisis de los filtros aplicados.

Filtro	Distinción entre patrones	Realce de características	Traslape
Suavizado	✓		
Detección	✓		
Restauración	✓	✓	
Morfológicos	✓		✓
Segmentación	✓ (Laplace)		✓

La cual describe que la técnica de filtrado ayuda a separar imágenes semejantes dentro de su clase, sin embargo, en la investigación se permite que cada una de las ANNs, tanto la *MLP* como la *SNN*, decidan que filtro es el que más aporta en la diferenciación de cerebros sanos y enfermos, de acuerdo a los pesos asociados con las entradas. Las clases utilizadas en las ANNs (Tabla 5.6) fueron las siguientes:

Tabla 5.7 Clases asociadas a las ANNs.

ANN	SANO	ENFERMO
<i>MLP</i>	1	0
<i>SNN</i>	2	5

Las tasas de aprendizaje utilizadas en ambas ANNs fueron de 0.02 y 0.05.

En el caso de la *SNN*, puesto que se trata de definir patrones mediante los *spikes*, se asignaron los valores de $\theta = 35$ y $\theta = 40$, esto mediante el análisis previo de los umbrales analizados en el Anexo H del CD.

En la *SNN* los valores de $\theta = 55$, $\theta = 56$ y $\theta = 57$ representaron la actividad más alta de la neurona, es decir, al evaluar el *spike* desde $\theta = 35$ ó $\theta = 45$, se observó que la neurona empezaba a desactivarse después de que $\theta = 57$.

Los resultados finales que se obtuvieron arrojaron los siguientes resultados:

- ❖ Dentro de la SNN cuando $\alpha = 0.02$ y $\theta = 35$ (Tabla 5.8):
 - ✓ Se observó que con un 80% de los datos en la etapa de aprendizaje, esta ANN tiene un buen rendimiento en la fase de aprendizaje o entrenamiento.
 - ✓ En su etapa de clasificación, suele responder de manera muy favorable cuando existe el mismo número de casos pertenecientes a un mismo patrón o clase. Incluso si los datos son escasos en el entrenamiento (75%), logra tener buen rendimiento en la clasificación.

Tabla 5.8 Los porcentajes indican el *accuracy* más alto generado de acuerdo al conjunto de datos usados mediante la técnica de validación cruzada, cuando $\alpha = 0.02$ y $\theta = 35$

CASOS	APRENDIZAJE	RECONOCIMIENTO
50 imágenes	80%,85%	80%
80 imágenes	85%	100% (cuando existía el mismo número de casos tanto para enfermos como para sanos)
85 imágenes	80%	75%
90 imágenes	90%,80%	75%
92 imágenes	80%,75%	80%, 75%

- ❖ Dentro de la SNN cuando $\alpha = 0.05$ y $\theta = 40$ (Tabla 5.8):
 - ✓ Se observó que teniendo un número elevado de casos y sólo analizados el 75% de ellos en la etapa de entrenamiento, la SNN tiene un buen resultado en la etapa de reconocimiento.
 - ✓ Debido a que el umbral aumenta, así como la tasa de aprendizaje, entre más casos se tengan, y aunque la muestra sea pequeña (75%) en la etapa de entrenamiento, se logra tener buen rendimiento en la clasificación.

Tabla 5.9 Los porcentajes indican el *accuracy* más alto generado de acuerdo al conjunto de datos usados mediante la técnica de validación cruzada, cuando $\alpha = 0.05$ y $\theta = 40$

CASOS	APRENDIZAJE	RECONOCIMIENTO
50 imágenes	80%	80%
80 imágenes	85%	85%, 75%
85 imágenes	80%,75%	75%
90 imágenes	75%	80%
92 imágenes	75%	85%, 80%

CAPÍTULO 6. CONCLUSIONES

En este capítulo se presentan las conclusiones de este trabajo de tesis, resumiendo los objetivos y alcances logrados, los resultados obtenidos, así como los productos, aportaciones y trabajos a futuro.

6.1 Objetivos y Alcances logrados

De acuerdo al objetivo general y a los objetivos específicos, se llevaron a cabo tareas propuestas para el cumplimiento de cada uno de ellos, como se describe en la siguiente Tabla:

Tabla 6.1 Objetivos y logros alcanzados en el trabajo de tesis.

OBJETIVOS	LOGROS
1.- Revisar y analizar el área de las ANNs.	Contenido del estado del arte
2.- Estudiar algoritmos y/o técnicas de reconocimiento de imágenes digitales.	Contenido del estado del arte. Programas en C++ y en el <i>guide</i> de Matlab para implementar los filtros: mediano, gaussiano, morfológico de dilatación, morfológico de erosión, <i>Prewitt</i> , Laplaciano, <i>Sobel</i> , inverso, histograma y escala de grises.
3.- Analizar e implementar una red neuronal de tipo pulsante aplicada al problema de visión artificial, dentro de imágenes médicas del cerebro humano.	Programa en C++ para la simulación de clasificación de imágenes. Implementación de la simulación de la neurona Izhikevich en Matlab y su modelado en Simulink.
4.- Experimentar con bases de datos de imágenes médicas digitales.	Programa en C++ de experimentación para el procesamiento de imágenes por medio de la red <i>MLP</i> y la Pulsante.
5.- Conocer las ventajas y desventajas de una SNN en el área de reconocimiento de imágenes.	Realización de un estudio comparativo y presentación de avances
6.- Análisis de los resultados obtenidos.	Presentación de resultados obtenidos.
ALCANCES	LOGROS
1.- Estudiar diversas ANNs tradicionales como: <i>MLP</i> , <i>SNN</i> , etc..	Contenido del estado del arte.
2.- Revisar y entender al menos 2 problemas típicos de las técnicas de <i>AV</i> y de las ANNs en el dominio de las imágenes médicas.	Primer capítulo de la tesis de investigación, además se generó un artículo referente al Estado Del Arte en base a las herramientas más utilizadas enfocándose en las ANNs.

Tabla 6.1 Objetivos y logros alcanzados en el trabajo de tesis. (continuación)

ALCANCES	LOGROS
3.- Implementar y analizar una SNN aplicada en la interpretación de imágenes médicas del cerebro humano.	Estado del arte y plataforma de experimentación.
4.- Experimentar al menos con dos bases de datos de imágenes digitales conocidas para la valoración de enfermedades cerebrovasculares	Estado del arte
5.- Realizar un estudio comparativo.	Estado del arte y plataforma de experimentación.

6.2 Conclusiones finales

Debido a que existe gran variedad de *BSD*, se siguen requiriendo especialistas para determinar y diagnosticar el tipo de enfermedad a tratar, sin embargo, la *AI* ha ayudado en la obtención de imágenes anatómicas con mayor resolución espacial (tamaño, densidad y claridad), permitiendo a los médicos tener una estructura y actividad cerebral más nítida que proporcione información funcional más detallada.

El uso de la herramienta de Matlab y su entorno visual *Simulink*, es ideal para el tratamiento digital de imágenes, ya que poseen funciones y herramientas que facilitan la manipulación y tratamiento de imágenes, simulando resultados de pruebas, los cuáles pueden ser comparados contra los resultados de un programa realizado en otro lenguaje de programación, como lo es C++ (dentro del CD se encuentran los archivos generados que contienen los vectores de características de cada una de las imágenes, que pueden ser comparados con los resultados arrojados por la aplicación en Matlab.).

Respecto a la experimentación con *ANNs*, se observó que en algunos casos, la función de transformación lineal presentaba mejores resultados que una función con producto punto, por lo que la *SNN* arrojó resultados de clasificación similares en comparación a la *ANN MLP*.

Para problemas de clasificación complejos, el uso de una sola neurona de *SNN* da la capacidad de hacer una clasificación de patrones por medio de pulsos o *spikes*.

Con el conjunto de datos de 111 imágenes cerebrales, el entrenamiento y validación del sistema también se realizó usando porcentajes de datos seleccionados del conjunto total de datos, que se resume en lo siguiente:

Aprendizaje y reconocimiento con $\alpha=0.02$

a) Se observó que con una selección de mínima de 75% de los datos, había un mayor número de cerebros con anomalías, es decir la neurona era capaz de reconocer cerebros sanos de los enfermos favorablemente.

b) Los peores casos tanto para el aprendizaje como para el reconocimiento oscilan cuando θ está en el rango de 58 hasta 65, es decir cuando el *spike* empieza a descender (Anexo H en el CD).

c) Cuando $\theta = 70$ el aprendizaje llega a un nivel muy bajo y por ende el reconocimiento era nulo.

d) Con esta tasa de aprendizaje se observa que:

- Aunque se cuente con un número de casos mínimos la neurona tiene un aprendizaje favorable.
- Entre más datos de entrada como aprendizaje tenga una neurona, hay un entrenamiento más rápido.
- Cuando se cuenta con un número casi idéntico de imágenes que pertenezcan al mismo patrón o clase en la fase de entrenamiento, la neurona sólo falla en alrededor del 28% de los datos si las imágenes contienen ruido (como el gaussiano, sal y pimienta, etc.).
- Cuando existe el mismo número de imágenes tanto de cerebros sanos como de cerebros con anomalías, y las imágenes son nítidas, el aprendizaje llega a alcanzar hasta el 100%.

e) En la fase de reconocimiento experimentando con distintos porcentajes de datos entrenados se observa que:

- Cuando se tiene un mismo número de muestras tanto de una clase como de otra, la SNN es capaz de hacer un reconocimiento muy eficiente.

- Su porcentaje más bajo de reconocimiento se generó con un número pequeño de datos y un conjunto de datos del 75%.
- El tener una tasa de aprendizaje pequeña augura un buen reconocimiento con pocos errores en la clasificación para los experimentos aquí descritos.

Aprendizaje y reconocimiento con $\alpha=0.05$

- a) Se observó que con pocos datos el aprendizaje alcanzaba los resultados más altos incluso usando diferentes porcentajes de datos seleccionados del conjunto total de datos.
- b) En este caso, cuantos más datos se tenían, el porcentaje de aprendizaje era menor, debido a que el valor de alpha era un poco más grande en relación al experimento anterior.
- c) Si había un mismo número de elementos de cerebros sanos y el mismo número de elementos de cerebros enfermos, el aprendizaje superaba el 90% de *accuracy*.
- d) En cuanto a su comportamiento en la fase de reconocimiento, se observó que:
 - Aún si en la etapa de aprendizaje se alcanzaba un porcentaje de *accuracy* menor, la etapa de reconocimiento o clasificación siempre superaba el aprendizaje.
 - Si había un mismo número de elementos de cerebros sanos y el mismo número de elementos de imágenes con cerebros con enfermedades se obtenía una clasificación relativamente baja.

A partir de la experimentación realizada, se demuestra la importancia que representan los parámetros de aprendizaje y reconocimiento en el desarrollo de una SNN; si estos parámetros no se encuentran bien ajustados puede generarse una convergencia lenta o algunas oscilaciones en el aprendizaje.

Por lo que mediante la utilización de diversas combinaciones de valores en los parámetros de α y θ se pudo determinar cuáles eran las constantes de aprendizaje y reconocimiento más favorables.

Se planteó el método de validación cruzada y accuracy tanto para el aprendizaje como para el reconocimiento a manera de evitar un sobreajuste y evaluar el comportamiento de la SNN.

Se pudo obtener un listado de ventajas y desventajas en el reconocimiento de imágenes con una SNN.

Ventajas:

- ✓ Las SNN operan utilizando pulsos o spikes, que son eventos discretos que tienen lugar en puntos en el tiempo en lugar de valores continuos, es decir, los datos (información) al igual que en la sinapsis biológica, se miden en virtud de pulsos o spikes generados a través de cierta duración.
- ✓ Con una sola neurona se puede realizar una clasificación favorable.
- ✓ El resultado de su clasificación puede arrojar más de 2 clases.
- ✓ Aminoran el tiempo en la fase de clasificación, ya que la SNN ofrece mejores resultados en un menor número de épocas, análogamente si la duración del potencial de acción se asemejara al número total de épocas de una MLP, la SNN podría clasificar en una frecuencia de 1,000 épocas en lugar de las 1,500 necesarias por una MLP con tasa de aprendizaje de 0.02.
- ✓ Emulan más detalladamente a una neurona biológica puesto que codifican información temporal a través de señales que generan pulsos o spikes.
- ✓ La capacidad de hacer la clasificación de patrones por medio de la frecuencia de disparo, disminuye el número de valores a ajustar y neuronas necesarias para realizar la tarea.

Desventajas:

- ❖ Existen diferentes modelos que emulan el comportamiento de una neurona biológica, teniendo importancia la generación de su potencial de acción, por lo que se tendrían que realizar distintas pruebas con cada uno ellos, para obtener parámetros correctos.

- ❖ El avance de las *SNN* pueden generar algoritmos derivados de los nuevos descubrimientos en la neurobiología, si bien ya se cuenta con aprendizaje biológicos no supervisados, como el aprendizaje de Hebbian y el STDP, para un entrenamiento supervisado, como lo es el modelo de Izhikevich con el gradiente de descenso, sin los ajustes correctos en diferentes parámetros, se puede perder información temporal precisa en la generación de los trenes de picos. Esto representa una tarea muy difícil, dado que implicaría determinar cómo aprende realmente el cerebro humano (cognición), dado el realismo biológico de éstas redes.
- ❖ Todavía la literatura sobre aplicaciones prácticas sigue siendo escasa, ya que la mayoría de los artículos son teóricos y se siguen creando reglas de aprendizaje supervisado de *SNN*.

6.3 Resultados del trabajo

Productos

1.- Plataforma de experimentación

Se desarrollaron programas en C++, así como una guide de Matlab y modelados en Simulink.

Se implementó un simulador en Matlab para analizar y estudiar el comportamiento de los filtros, estos se modelaron usando la herramienta de Simulink.

Se realizó una revisión bibliográfica exhaustiva de los diferentes métodos de clasificación de SNNs; esta revisión puso de manifiesto la variedad de comportamiento que tienen este tipo de neuronas y lo semejante de su dinámica a una neurona biológica.

Se simuló el comportamiento de la neurona de Izhikevich de manera gráfica en Matlab.

2.- Base de datos de imágenes cerebrales en *MRI*

Un conjunto de 111 imágenes cerebrales (51 de cerebros sanos y 60 de cerebros con anomalías) con un tamaño de 512x512píxeles en formato *.jpg.

3.- Dos publicaciones en congresos nacionales

- Se realizó la investigación de 80 referencias, para la realización del artículo titulado "Estado del Arte y Elementos del Reconocimiento Automático de Imágenes del Cerebro". el cuál registró *120 técnicas, 5 algoritmos y 5 herramientas de software* aplicadas en diferentes etapas del estudio de imágenes cerebrales, concluyendo que las técnicas de Umbralización, Filtrado y Redes Neuronales Artificiales aparecieron en todas las etapas; dicho trabajo fue parte del proyecto del TecNM 5683.16-P. Se expuso en el 9° Congreso Mexicano de Inteligencia Artificial (COMIA 2017), con sede en el Tecnológico de Monterrey Campus Toluca, celebrado del 22 al 27 de mayo de 2017, dicho

artículo se registró en la revista Research in Computing Science 140 (2017) ISSN 1870-4069

- Se publicó, organizó y amplió a 87 referencias el artículo anterior, en el *International Conference on Mechatronics, Electronics and Automotive Engineering 2017 (ICMEAE/IEE)*, con el título de “State of the art and elements of the brain automatic Image Recognition”, celebrado del 21 al 24 de noviembre del 2017 en Cuernavaca, Morelos, donde se organizaron técnicas utilizadas en las etapas comunes de la interpretación de imágenes, dicho artículo se registró como ISBN 978-1-5386-2532-3/17 DOI 10.1109/ICMEAE.2017.30, pp.13-25.

4.- Colaboración en dos proyectos de investigación

- Se participó en el proyecto “Medic Spikes”, en el concurso local del Evento Nacional Estudiantil de Innovación Tecnológica 2016 (ENEIT), el cual, por medio de una aplicación usando redes neuronales pulsantes realizaba el análisis de electroencefalogramas.
- Se participó en el proyecto TecNM 5683.16-P, del Tecnológico Nacional de México, titulado” Interpretación Automatizada de Imágenes Médicas de pacientes que sufren enfermedad vascular cerebral mediante la aplicación de redes neuronales artificiales de tercera generación”, donde mediante el análisis de imágenes de MRI y técnicas de probabilidad, se detectaban anomalías cerebrales.

Aportaciones

A partir de un análisis exhaustivo del estado del arte, se planteó una clasificación de diferentes tipos de SNN encontradas en la literatura.

Aunque dentro del CENIDET existen investigaciones enfocadas en las ANNs, este trabajo de tesis es el segundo que contribuye en el estudio de las SNN en el área de Visión Artificial, generando un panorama en la tarea de clasificación de imágenes médicas cerebrales.

El método utilizado en la SNN aplicada al problema de reconocimiento de patrones, proporciona una base teórica-práctica con el modelo de Izhikevich que ayuda a comprender los principios de las reglas de aprendizaje biológicas, mediante la clasificación de imágenes por medio de pulsos.

6.4 Trabajos futuros

Con base en los resultados obtenidos, se recomienda continuar las actividades de investigación en:

- De acuerdo al área cerebral proporcionada por una imagen, o a partir imágenes generadas en tiempo real como lo son los EEG, adaptar al sistema para que ejecute el reconocimiento de BSD específicas que ayuden a diagnosticar alguna enfermedad en específico.
- Se podría hacer uso de un lenguaje de programación en paralelo para simular una SNN con el fin de generar una clasificación con un mayor número de clases, además de agilizar las dos fases (aprendizaje y reconocimiento).
- Debido a que sólo se usó el comportamiento de la neurona del tipo “*regular spike*”, se puede ejemplificar el modelo de Izhikevich con diferentes tipos de respuesta con el propósito de generar y comprender los fenómenos que ocasionan, como por ejemplo, en el cambio en la corriente de entrada.
- De acuerdo a la clasificación de las SNN encontrada en la literatura, se podría ejemplificar una SNN con otros modelos de aprendizaje como el no supervisado.

REFERENCIAS

- [Abdulrahman, 2015] Abdulrahman, Alhawaimil. 2015, *Segmentation of Brain Stroke Image*. International Journal of Advanced Research in Computer and Communication Engineering. Vol.4 Number 9, pp. 375-378.
- [Aguilar, 2012] Aguilar J., Jorge. 2012, *Introducción a las redes neuronales artificiales*. Facultad de Ingeniería, Pontífica Universidad Católica del Ecuador. pp. 1-30
- [Agwu, 2016] Agwu, Kenneth; Ohagwu, Christopher C. 2016, *Histogram-Based Texture Characterization and Classification of Brain Tissues in Non-Contrast CT Images of Stroke Patients*. Pattern Recognition - Analysis and Applications. INTECH: Open Science|Open Minds. pp. 81-108. DOI: <http://dx.doi.org/10.5772/65349>.
- [Ahmed, 2014] Ahmed, Falah Y.H.; Yusob, Bariah; Abdull Hamed, Haza Nuzly. 2014, *Computing with Spiking Neuron Networks: A Review*. SCRG Publication, Int. J. Advance. Soft Comput. Appl. Vol.6 Number 1 pp. 1-21. ISSN: 2074-8523.
- [Alet, 2015] Alet, Matías; Fernández, Victoria; Dorman, Guido; Avelle, Maira; Quarracino, Cecilia; Lepera, Sandra; Rey, Raúl. 2015, *Accidente cerebrovascular isquémico asociado a realización de ecografía Doppler de vasos de cuello: ¿casualidad o causalidad?*. Neurología, Argentina. Vol.7, Number 2. DOI:10.1016/j.ne-uarg.2015.02.001
- [Anusha, 2012] Anusha, Kondepudi; Meera, Treesa Mathews; Puthankattil, Subha D. 2012, *Classification of Normal and Epileptic EEG Signal using Time & Frequency Domain Features through Artificial Neural Network*. International Conference on

- Advances in Computing and Communications, August 2012. pp. 98-101 DOI: 10.1109/ICACC.-2012.21
- [Aqhsa, 2014] Aqhsa, Q. Syed; Narayanan, K. 2014, *Detection of Tumor in MRI Images Using Artificial Neural Networks*. International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, September. Vol.3 Number 9
- [Banda, 2015] Banda Gamboa, Dr.Hugo A. 2015, *Inteligencia Computacional: Computación Neuronal*. CORDICYT,2015. <https://es.slideshare.-net/hbanda/computacin-neuronal>
- [Baume, 2011] Baume, Dr. G.L. 2011, *Astronomía Observacional: Procesamiento de Imágenes*. Facultad de Ciencias Astronómicas y Geofísicas. Universidad Nacional de La Plata.
- [Bhaiya, 2012] Bhaiya,Lalit P.; Kumar Verma, Virendra. 2012, *Classification of MRI Brain Images Using Neural Network*. International Journal of Engineering Research and Applications. Vol.2 Number 5 pp. 751-756.
- [Blanco, 2011] Blanco González, M.; Arias Rivas, S.; Castillo Sánchez, J. 2011, *Diagnóstico del accidente cerebrovascular isquémico. Protocolos de Práctica asistencial*. Unidad de Ictus. Área de Neurociencias. Servicio de Neurología. Hospital Clínico Universitario. Santiago de Compostela, España. pp. 4919-4923.
- [Boudjelal, 2012] Boudjelal, Meftah; Lézoray, Olivier; Chaturvedi, Soni; Khurshid, Aleefia A.; Abdelkader, Benyettou. 2012, *Image Processing with Spiking Neuron Networks*. Springer-Verlag Berlin Heidelberg. pp. 525-544.
- [Bohte, 2003] Bohte, Sander; Paugam-Moisy, Hélène. 2003, *Computing with Spiking Neuron Networks*. Universit de Lyon Laboratoire de Recherche en Informatique - INRIA - CNRS bat. 490, Universit Paris-Sud.

- [Bohte, 2017] Bohte, S. M.; Alonso Saría, Francisco. 2017, *Tema 6. Técnicas de filtrado*. SIGMUR, SIG y Teledetección en la Universidad de Murcia
- [Cádenas, 2015] Cárdenas Sotelo, Selene. 2015, Tesis de Maestría en Ciencias: *Implementación y Evaluación de Redes Neuronales Artificiales tipo "Pulse - Coupled Neural Networks"(PCNN) aplicadas a Visión Artificial*. Cuernavaca, Morelos. CENIDET.
- [Casares, 2015] Casares Cruz, Dra. Katiuzka. 2015, *La enfermedad vascular cerebral en México: un problema de salud en incremento*. Instituto Nacional de Neurología y Neurocirugía. Anales de Radiología México 2015. Vol.14 pp.243-244
- [Ceballos, 2010] Ceballos Herrera, Andrea. 2010, *Detección de epilepsia en señales de electroencefalografía, mediante el uso de RNA y MSV*. Facultad De Ingeniería. Programa De Ingeniería Biomédica, Universidad Autónoma De Occidente. Santiago de Cali.
- [Chaturvedi, 2011] Chaturvedi, Mrs.Soni; Khurshid, A.A. 2011, *Review of Spiking Neural Network Architecture for Feature Extraction and Dimensionality Reduction*. 2011 Fourth International Conference on Emerging Trends in Engineering & Technology. Nagpur, India. pp.317-322. DOI: 10.1109/ICETET.2011.57
- [Chaturvedi, 2015] Chaturvedi, M.; Kurshid, D. 2015, *ASIC Implementation for Improved Character Recognition and Classification using Snn Model*. The 2015 International Conference on Soft Computing and Software Engineering (SCSE 2015). pp. 151-158.
- [Chaturvedi, 2014] Chaturvedi, Soni; Neha R. Sondhiya; Rutika N. Titre. 2014, *Izhikevich Model Based Pattern Classifier For Handwritten*
-

- Character Recognition- A Review Analysis*. 2014 International Conference on Electronic Systems, Signal Processing and Computing Technologies. Pages 346-349 DOI: 10.1109/-ICESC.2014.65
- [Chaturvedi, 2012] Chaturvedi, Soni; Boudjelal, Meftah; Khurshid, A.A. 2012, *Image Segmentation using Leaky Integrate and Fire Model of Spiking Neural Network*. International Journal of Wisdom Based Computing, April. Vol.2 Number 1 pp. 21-28.
- [Chawla, 2009] Chawla, M.; Sharma, S.; Sivaswamy, J. 2009, *A method for automatic detection and classification of stroke from brain CT images*. Engineering in Medicine and Biology Society (EMBS). pp. 3581–3584.
- [Chyzhyk, 2015] Chyzhyk, Darya; Dacosta-Aguayo, Rosalía; Mataró, María; Graña, Manuel. 2015, *An Active Learning Approach for Stroke Lesion Segmentation on Multimodal MRI Data*. Neurocomputing. Neurocomputing, Barcelona, España. February. Vol.150, pp. 26-36. DOI:<https://doi.org/10.1016/j.neucom.2014.01.077>.
- [Clopath, 2010] Clopath, C. 2010, *Connectivity reflects coding: a model of voltage-based stdp with homeostasis*. Nature Neuroscience. Vol.13 Number 3, pp. 344-352.
- [Cortés-Martínez, 2017] Cortés-Martínez, Keila Vasthi; Mejia-Lavalle, Manuel; Ruiz Ascencio, José. 2017, *State of the Art and Elements of the Brain Automatic Image Recognition*. International Conference on Mechatronics, Electronics and Automotive Engineering (ICMEAE). pp. 13-25. DOI:10.1109/ICMEAE.2017.30
- [CYTED-CONICIT, 2012] CYTED-CONICIT. 2012, *Aplicaciones de las redes de neuronas en supervisión, diagnóstico y control de procesos*.

- Universidad Simón Bolívar, Venezuela. Ed.Equinoccio. Vol. VII, Number 5 DOI:980-237-190-4
- [Davies,2012] Davies, Sergio. 2012, *Learning In Spiking Neural Networks*. A thesis submitted to the University Of Manchester For The Degree Of Doctor Of Philosophy In The Faculty Of Engineering And Physical Sciences. School of Computer Science.
- [Deshpande, 2018] Deshpande, Adit. 2018, *A Beginner's Guide To Understanding Convolutional Neural Networks*. <https://adeshpande3.github.io/adeshpande3.github.io/A-Beginner%27s-Guide-To-Understanding-Convolutional-Neural-Networks/>
- [DespotoviT, 2015] DespotoviT, Ivana; Goossens, Bart; Philips, Wilfried. 2015, *MRI Segmentation of the Human Brain: Challenges, Methods, and Application*. Hindawi Publishing Corporation Computational and Mathematical Methods in Medicine. 23 pages.
- [Devijver, 1982] Devijver, P.A.; Kittler, J. 1982, *Pattern Recognition: A Statistical Approach*. Prentice-Hall.
- [Dhilipan, 2014] Dhilipan, A.; Preethi, J.; Sreeshakthy, M.; Sangeetha, V. 2014, *A survey on pattern recognition using spiking neural networks with temporal encoding and learning*. International Journal of Research in Advent Technology, November. Vol.2 Number 11 pp. 121-125, DOI:2321-9637.
- [Diehl, 2014] Diehl, Peter U.; Cook, Matthew. 2014, *Unsupervised Learning Of Digit Recognition Using Spike-Timing-Dependent Plasticity*. Institute of Neuroinformatics, ETH Zurich and University Zurich. IEE Transactions in Neural Networks and Learning Systems. pp. 1-6

- [Dimililer, 2016] Dimililer, Kamil A. İ. 2016, *Effect of image enhancement on MRI brain images with neural networks*. 12th International Conference on Application of Fuzzy Systems and Soft Computing(ICAFS 2016), August. pp. 39-44
- [Donachy, 2015] Donachy, Shaun. 2015, *Spiking Neural Networks: Neuron Models, Plasticity, and Graph Applications*. Richmond, Virginia(Virginia). Virginia Commonwealth University (VCU) Scholars Compass. United States of America.
- [Dridi, 2016] Dridi, Manuel; Bouallegue, Belgacem; Ali Hajjaji, Mohamed; Mtibaa, Abdellatif. 2016, *An Enhancement Medical Image Compression Algorithm Based on Neural Network*. International Journal of Advanced Computer Science and Applications. Vol.2 Number 5.
- [Duda, 2001] Duda, Richard O.; Hart, Peter E.; Stork, David G. 2001, *Pattern Classification*. Second ed. California, USA: John Wiley and Sons. 680 pages. DOI: 978-0-471-05669-0.
- [El-Dahshan, 2014] El-Dahshan, El-Sayed A.; Mohsen, Heba M.; Revett, Kenneth; Salem, Abdel-Badeeh M. 2014, *Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm*. Expert Systems with Applications. Vol.41 pp. 5526–5545
DOI:<http://dx.doi.org/10.1016/j.eswa.2014.01.021>
- [Escudero,2015] Escudero, D. 2015, *Doppler transcraneal en el diagnóstico de la muerte encefálica. ¿Es útil retrasar el diagnóstico?*. Medicina Intensiva.
- [FECYT, 2007] FECYT, 2007. 2007, *Unidad Didáctica: Viaje al Universo Neuronal*. Fundación Española para la Ciencia y la Tecnología(FECYT).

- [Fernández, 2012] Fernández, Jéssica; Martínez Sánchez, Patricia; García Rodríguez, Raquel. 2012, *El eco-doppler color transcraneal en el estudio*. Argentina.
- [François, 2015] François, Christophe; Mikkonen, Tommi; Andalibi, Vafa; Koskimies, Kai; Laukkarinen, Teemu. 2015, *Pattern recognition with spiking nerual networks: a simple training method*. SPLST'15. Tampere University of Technology, Finland. pp.296-308.
- [García, 2010] García Fenoll, I. 2010, *Capítulo II: Imágenes Médicas. Aportaciones a la Segmentación y Caracterización de Imágenes Médicas 3D*. Madrid, España.
- [González, 2010] González Montoro, Aldana M. 2010, *Análisis Estadístico de Trenes de Potenciales de Acción*. Proyecto Fin de Máster Máster en Técnicas Estadísticas. Universidade da Coruña.
- [Grüning, 2014] Grüning, André Elman; Bohte, Sander M. 2014, *Spiking Neural Networks:Principles and Challenges*. European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning. Bruges, Bélgica. pp. 23-25. ISBN 978-287419095-7
- [Grüning, 2007] Grüning, André Elman. 2007, *Neural Computation: Backpropagation as reinforcement for simple recurrent networks*. Vol.19 Number 11 pp.3108-3131. DOI:0899-7667
- [Guo, 2009] Guo, Ling; Rivero, D.; Seoane, Jose A.; Pazo, Alejandro. 2009, *Classification of EEG Signals Using Relative Wavelet Energy and Artificial Neural Networks*. GEC. pp. 177-183
- [Gupta, 2015] Gupta, Deep; Singh, Sneha; Anand, R.S.; Kumar, Vinod. 2015, *Nonsampled shearlet based CT and MR medical image fusion using biologically inspired spiking neural network*. Elsevier. Biomedical signal Processing and control. Vol.18 pp. 91-101. DOI:10.1016/j.bspc.2014.11.009

- [Hernández, 2017] Hernández Becerra, Christian. 2017, Tesis de Maestría en Ciencias: *Aplicación del Descenso de Gradiente para el aprendizaje de neuronas pulsantes Izhikevich*. Cuernavaca, Morelos. CENIDET.
- [Hernández-Becerra, 2016] Hernández-Becerra, Christian; Mejía-Lavalle, Manuel. 2016, *Clasificación de patrones mediante el uso de una red neuronal pulsante*. Research in Computing Science. Vol.116 pp. 81-91.
- [Iakymchuk, 2015] Iakymchuk, Taras; Rosado-Muñoz, Alfredo; Guerrero-Martínez, Juan F.; Bataller-Mompeán, Manuel; Francés-Víllora, José V. 2015, *Simplified spiking neural network architecture and STDP learning algorithm applied to image classification*. EURASIP Journal on Image and Video Processing. Vol.4 pp. 1-11. DOI:10.1186/s13640-015-0059-4
- [Igwe, 2016] Sunday Igwe, Joseph; Inyama, H. C. 2016, *Classification of Human Brain Signal for Diagnosis of Stroke Disease Using Artificial Neural Network*. International Conference on Computing Research and Innovations(CoRI'16), Nigeria. pp. 234-236
- [Isoardi, 2010] Isoardi, Roberto A.; Mato, Germán; Kuperman, Marcelo. 2010, *Optimización de análisis y registración de imágenes tomográficas*. Centro Atómico Bariloche, Instituto Balseiro, Universidad Nacional de Cuyo, Comisión Nacional de energía Atómica, Argentina.
- [Izhikevich, 2003] Izhikevich, Eugene M. 2003, *Simple model of Spiking Neurons*. IEEE Transactions on neural networks. Vol.146 pp. 1569-1572
- [Izhikevich, 2004] Izhikevich, Eugene M. 2004, *Which Model to Use for Cortical Spiking Neurons?*. IEEE TRANSACTIONS ON NEURAL NETWORKS, September. Vol.15 Number 5, pp. 1063-1070.
-

- [Jalilvand, 2011] Jalilvand, M.; Li, X.; Zwick, T.; Wiesbeck, W.; Pancera, E. 2011, *Hemorrhagic stroke detection via UWB medical imaging*. Proceedings of the 5th European Conference on Antennas and Propagation (EUCAP). pp. 2911-2914.
- [Johnson, 1999] Johnson, John L.; Padgett, Mary Lou. 1999, *PCNN Models and Applications*. IEEE TRANSACTIONS ON NEURAL NETWORKS, Mayo. Vol.10 Number 3, DOI:1045-9227(99)03191-4.
- [Karthikeyan, 2016] S.Karthikeyan, D. M. 2016, *Automatic Stroke Lesion Segmentation From Diffusion Weighted Mri Images*. International Journal of Advanced Engineering Technology. Vol.VII, Issue II, pp. 111-115.
- [Kiani, 2015] Kiani, Kouros; Mohsenzadeh Korayem, Elmira. 2015, *Classification Of Persian Handwritten Digits Using Spiking Neural Networks*. 2nd International Conference on Knowledge-Based Engineering and Innovation (KBEI), IEEE, 5-6 November. pp. 1113-1116, DOI:978-1-4673-6506-2/15
- [Kupershtein,2016] Kupershtein, Leonid; Martyniuk, Tetyana; Voitovych, Olesya; Krentsin, Mihail. 2016, *Neural Network Approach in the Stroke Diagnosis*. IEEE First International Conference on Data Stream Mining & Processing, Vinnytsia National Technical University, Lviv, Ukraine. pp.138-141. DOI:978-1-5090-3736-0/16
- [Larrañaga, 2015] Larrañaga, Pedro; Inza, Iñaki; Moujahid, Abdelmalik. *Tema 8.Redes Neuronales*. Departamento de Ciencias de la Computación e Inteligencia Artificial 2015. Universidad del País Vasco–Euskal Herriko Unibertsitatea.

- [Lluís, 2013] Lluís, Joseph; Lacueva, Joaquín; Janpere, Ramon. 2013, *La era de la computadora*. Ediciones Culturales Internacionales. Primera edición, Espejo de Urania, SEP. Vol.4, Number 73.
- [Lujano,2014] Lujano, Efraín; Lujano, Apolinario; Pitágoras Quispe, José; Lujano, René. 2014, *Pronóstico de caudales medios mensuales del Río Ilave usando modelos de redes neuronales artificiales*. Servicio Nacional de Meteorología e hidrología. Ingeniería en sistemas. Universidad Nacional del Altiplano, Puno-Perú. ISSN: 2306-8582
- [Maass, 1997] Maass, Wolfgang. 1997, *Networks of Spiking Neurons: The Third Generation of Neural Network Models*. Neural Networks, Vol.10 Number(9), Institute for Theoretical Computer Science. Technische Universität Graz. pp. 1659-1671, DOI:0893-6080/97
- [Maida, 2015] Maida, Anthony S.; Amirhossein, Tavanaei. 2015, *A Minimal Spiking Neural Network to Rapidly Train and Classify Handwritten Digits in Binary and 10- Digit Tasks*. (IJARAI) International Journal of Advanced Research in Artificial Intelligence. Lafayette, LA, USA. Vol.4, Number 7.
- [Marrero, 2018] Marrero, Ph.D. Prof. Eddie. <http://academic.uprm.edu/eddiem/psic3001/id36.htm>
- [Martin, 2015] Martin, Henry. 2015, Thesis: *Spiking neural networks for vision tasks*. Neuroscientific System Theory, Technische Universität München. Múnich, Alemania. pp.1-21
- [Martínez-Vila, 2011] Martínez-Vila, E.; Fernández, M.; Pagola, I.; Irimia, P. 2011, *Enfermedades Cerebrovasculares*.
- [Matadamas, 2014] Matadamas Ortiz, Idarh Claudio. 2014, Tesis: *Aplicación de las Redes Neuronales Pulsantes en el reconocimiento de patrones y análisis de imágenes*. Centro de investigación en Computación, Instituto Politécnico Nacional. México, D.F.

- [Matamoros, 2009] Matamoros, Claudio; Scherle, Enrique; Pérez N, Jesús. 2009, *Utilidad del ultrasonido Doppler transcraneal en Neurología*. Hospital Clínicoquirúrgico "Hermanos Ameijeiras". Unidad de Ictus. La Habana, Cuba.
- [Maxinez, 2007] Maxinez, David G.; Alcalá, Jessica. 2007, *VHDL: El arte de programar sistemas digitales*. Compañía Editorial Continental, Instituto Tecnológico y de Estudios Superiores de Monterrey, Campus Estado de México, 3a impresión, México. ISBN 970-24-0259-X.
- [Menaka, 2015] Menaka, R.; Kanchana, R. 2015, *Computer Reinforced Analysis for Ischemic Stroke Recognition: A review*. Indian Journal of Science and Technology. Vol.8, Number 35, DOI:10.17485/ijst/2015/v8i35/81006
- [Menze, 2016] Menze, Bjoern H.; Leemput, Koen Van; Lashkari, Danial. 2016, *A Generative Probabilistic Model and Discriminative Extensions for Brain Lesion Segmentation With Application to Tumor and Stroke*. IEEE Transactions On Medical Imaging. Vol.35
- [Merino,2011] Merino Pérez,Jesús; Noriega Borge, María José. 2011, *Fisiología General: Señales eléctricas. 3)Potenciales de acción*. Open Curse Ware. Universidad de Cantabria.
- [Mills, 2016] Mills, Michael. 2016, *Artificial Intelligence in Law: The State of Play 2016*. The Answer company Thomson Reuters, Neota Logic. Vol.1. DOI:<http://www.legalexecutiveinstitute.com/artificial-intelligence-in-law-the-state-of-play-2016-part-1/>
- [Monge-Pereira, 2014]. Monge-Pereira, E.; Molina-Rueda, F.; Rivas-Montero, F.M.; Ibáñez, J.; Serrano, J.I.; Alguacil-Diego, I.M.; Miangolarra-Page, J.C. 2014, *Electroencefalografía como método de*

- evaluación tras un ictus. Una revisión actualizada. Neurología.*
- [OPS, 2014] OPS(Organización Panamericana de la Salud). 2014, *MÉXICO: Perfil de Enfermedades Cardiovasculares*. Revista de la Facultad de Medicina de la UNAM, México. pp. 11
- [Ortiz, 2016] Ortiz Rangel, Estela. 2016, Tesis de Maestría en Ciencias: *Detección de ruido impulsivo o Gaussiano en imágenes monocromáticas mediante redes neuronales pulso-acopladas*. Cuernavaca,Morelos. CENIDET.
- [Paugam-Moisy,2006] Paugam-Moisy,Pr.Hélène. 2006, *Spiking Neurons for Temporal Pattern Recognition:Importance of time*. ISC-CNRS, Institut des Sciences Cognitives, Lyon - France, IDIAP Research Institute, Martigny - Suisse, Groupe de travail LIMSI - 17 mars 2006.
- [Peralta, 2011] Peralta I.; Molas, J.T.; Martínez, C.E; Rufiner, H.L. 2011, *Implementación de una Red Neuronal Pulsante Parametrizable en FPGA*. XIV reunión de procesamiento de la información Control.
- [Ponulak, 2011] Ponulak, Filip; Kasiński, Andrzej. 2011, *Introduction to spiking neural networks: Information processing, learning and applications*. ACTA: Neurobiologiae Experimentalis. Polish Neuroscience Society - PTBUN, Nencki Institute of Experimental Biology. Vol.71, pp. 409-433.
- [Pukish, 2013] Pukish, Michael S.; Wang, Shumin; Wilamowski, Bogdan M. 2013, *Segmentation of Cerebral Cortex MRI Images with Artificial Neural Network (ANN) Training*. HSI 2013, Sopot, Polonia. pp. 320-327
- [Ramírez,2011] Ramírez Q.Juan A.; Chacón M., Mario I. 2011, *Redes neuronales artificiales para el procesamiento de imágenes, una revisión de la última década*. Revista De Ingeniería

- Eléctrica, Electrónica Y Computación(Riie&C), JULIO 2011. Vol.9, Number 1, pp. 7-16, ISSN 1870 - 9532
- [Rihiardi, 2013] Rihiardi, J. 2013, *Machine Learning with Brain Graphs*. IEEE Signal Processing Magazine. Vol.30, Number 3, pp. 58-70
- [Rotariu, 2013] Rotariu, C.; Hariton, C. 2013, *Medical Image Processing by means of some Artificial Intelligence methods*. BULETINUL INSTITUTULUI POLITEHNIC DIN IASI.
- [Ruiz, 2015] Ruiz del Solar, Javier; Loncomilla, Patricio; Orellana, Pedro; Gálvez Ortiz, Sebastián. 2015, *Filtrado de imágenes y ecualización de histograma*. EL7008 - Procesamiento avanzado de imágenes, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile. Septiembre. pp. 1-36
- [Salas, 2011] Salas, Rodrigo. 2011, *Redes Neuronales Artificiales*. Departamento de Computación. Universidad de Valparaíso. pp. 1-7
- [Shaswati, 2015] Shaswati, Roy; Pradipta, Maji. 2015, *A simple skull stripping algorithm for brain MRI*. 2015 Eighth International Conference on Advances in Pattern Recognition (ICAPR), Kolkata, 2015, pp. 1-6. DOI: 10.1109/ICAPR.2015.7050671
- [StrokeCenter, 2018a] Copyright © 1997-2018 - The Internet Stroke Center. 2018, *The internet Sroke Center an independent web resource for information about stroke care and research*. <http://www.strokecenter.org/patients/about-stroke/intracerebral-hemorrhage>
- [StrokeCenter, 2018b] Copyright © 1997-2018 - The Internet Stroke Center. 2018, *The internet Sroke Center an independent web resource for information about stroke care and research*. <http://www.strokecenter.org/patients/about-stroke/ischemic-stroke/>

- [Suryawanshi, 2015] Suryawanshi, Santosh H.; Jadhao, K. T. 2015, *Smart brain hemorrhage diagnosis using artificial neural networks*. International Journal Of Scientific & Technology Research. Vol.4, Number 10, pp. 267-261, ISSN 2277-8616
- [Tajbakhsh, 2016] Tajbakhsh, Nima; Shin, Jae Y.; Gurudu, Suryakanth R. 2016, *Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?*. IEEE Transactions on Medical Imaging. Vol.35, Number 5, pp. 1299 – 1312, DOI:10.1109/TMI.2016.2535302
- [Tapson,2013] Tapson*, Jonathan C.; Cohen, Greg K.; Afshar, Saeed; Stiefel, Klaus; Yossi, Buskila M.; Runchun, Mark Wang; Hamilton, Tara J.; Van Schaik, André. 2013, *Synthesis of neural networks for spatio-temporal spike pattern recognition and processing*. The MARCS Institute, University of Western Sydney, Kingswood, NSW, Australia, 30 August 2013. <https://doi.org/10.3389/fnins.2013.00153>
- [Torres, 2007] Torres Soler, Luis Carlos. 2007, *Inteligencia Artificial: Aprendizaje de máquinas (Machine Learning)*. Facultad de Ingeniería. Departamento de Sistemas e Industrial, Universidad Nacional de Colombia. Bogotá, Colombia.
- [Uc-Cetina, 2012] Uc-Cetina, Víctor. 2012, *Aprendizaje por refuerzo*. Facultad de Matemáticas. Universidad Autónoma de Yucatán. pp. 1-2
- [Wang, 2014] Wang, Jinling; Belatreche, Ammar; Maguire, Liam; Martin McGinnity, Thomas. 2014, *An online supervised learning method for spiking neural networks with adaptive structure*. Neurocomputing.Intelligent Systems Research Centre, School of Computing and Intelligent Systems, University of Ulster, England. Vol.144, pp. 526-536.
- [Yu, 2014] Yu, Qiang; Tang, Huajin; Chen Tan, Kay; Yu, Haoyong. 2014, *A brain-inspired spiking neural network model with temporal*
-

- encoding and learning*. Neurocomputing, National University of Singapore, Singapore. Vol.138, pp. 3-13
- [Zárate, 2015] Zárate Galindo, Mario Bismarck. 2015, Tesis de Maestría en Ciencias: *Extracción de descriptores de imágenes digitales mediante una red neuronal artificial pulsante*. Cuernavaca, Morelos. CENIDET.
- [Zhang, 2016] Zhang, Le; Suganthan, P.N. 2016, *A survey of randomized algorithms for training neural networks*. Information Sciences. NanYang Technological University. Vol.364–365, pp. 146–155