



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Segmentación Digital de Imágenes del Cerebro con el Modelo
Neuronal de Intersección Cortical

presentada por

José Luis Soto Piña

como requisito para la obtención del grado de
Maestría en Ciencias de la Computación

Director de tesis

Dr. Manuel Mejía Lavalle

Codirectora de tesis

Dra. Andrea Magadán Salazar

Cuernavaca, Morelos, México. Diciembre de 2020



Cuernavaca, Mor., **16/diciembre/2020**

OFICIO No. DCC/124/2020
Asunto: Aceptación de documento de tesis
CENIDET-AC-004-M14-OFICIO

C. DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial del **C. Ing. José Luis Soto Piña**, con número de control M18CE068, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **"Segmentación Digital de Imágenes del Cerebro con el Modelo Neuronal de Intersección Cortical"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

Dr. Manuel Mejía Lavalle
Doctor en Ciencias Computacionales
8342472
Director de tesis

Dra. Andrea Magadán Salazar
Doctorado en Ciencias Computacionales
10654097
Co-directora de tesis

M.C. Gerardo Reyes Salgado
Maestro en Ciencias de la Computación
2493370
Revisor 1

Dr. José Ruiz Ascencio
Doctor en Ciencias
5009035
Revisor 2

C.c.p. Depto. Servicios Escolares
Expediente / Estudiante
JGG5/lmz



Centro Nacional de Investigación y Desarrollo Tecnológico

"2020, Año de Leona Vicario, Benemérita Madre de la Patria"

Cuernavaca, Morelos **18/diciembre/2020**

OFICIO No. SAC/ 293/2020

Asunto: Autorización de impresión de tesis

JOSÉ LUIS SOTO PIÑA
CANDIDATO AL GRADO DE MAESTRO 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 *"Segmentación Digital de Imágenes del Cerebro con el Modelo Neuronal de Intersección Cortical"*, 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"



SEP TecNM
CENTRO NACIONAL
DE INVESTIGACIÓN
Y DESARROLLO
TECNOLÓGICO
SUBDIRECCIÓN
ACADÉMICA

DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO

C.c.p. M.E. Guadalupe Garrido Rivera, Jefa del Departamento de Servicios Escolares
Expediente
CMAZ/CHG

Interior Internado Palmira S/N, Col. Palmira, C. P. 62490, Cuernavaca, Morelos.

Tel. (01) 777 3 62 77 70, ext. 4105, e-mail: dir_cenidet@tecnm.mx

www.tecnm.mx | www.cenidet.edu.mx



Dedicatoria

Este trabajo de tesis se lo dedico a Dios y a mi Familia porque de ellos he recibido vida, amor, cariño, bendiciones, comprensión, tolerancia, protección, sustento, motivación, fortaleza ... en el plano terrenal, la familia es lo más importante.

A mis padres Feliza Piña Ramírez y Tomás Soto González ...

A mi esposa Lourdes Mendoza Cervantes ...

A mis hijos Christian, Daniela, Gabriel y Rafael ...

A mis nietos Isaac, David y Leonardo ...

A mis hermanos Carmen, María, Manuela, Victoria, Miguel, Tita,

Juana y Kory ...

A mis abuelos ...

A mi nuera Gaby ...

A mis sobrinos ...

A mis primos ...

A mis tíos ...

A mis cuñados y cuñadas ...

A los que no mencioné y son familia.

AGRADECIMIENTOS

“Siempre deberíamos ser agradecidos por las cosas que se nos dan”

Primeramente, agradezco a Dios por su ayuda y acompañamiento en todo momento. Por darme la salud, fuerza, la motivación y la voluntad en la realización de esta empresa, y de todas las que me he propuesto. Él siempre está ahí, solo hay que pedir y agradecer.

A mis padres Feliza y Tomás y a y mis hermanos, por su apoyo siempre incondicional, en especial a mi mama Feliza por su devoción, dedicación y amor hacia nosotros, sus hijos, a mi hermana Carmen que siempre ha estado al pendiente, y a mi hermano Miguel, ejemplo a seguir, de quien recibí mucho apoyo, sobre todo en la Licenciatura.

A mi esposa Lourdes por su apoyo incondicional e inapreciable en todas y cada una de las empresas que me he propuesto, por desatinadas que éstas parecieran.

A mis hijos: Christian, Daniela, Gabriel y Rafael por creer en que podía lograrlo, y por el apoyo en muchos aspectos, que faltaría espacio para enumerar. En especial las inapreciables sugerencias y apoyo técnico de mi hijo Christian.

Al Sistema de Bachillerato y Educación Superior (SABES), institución educativa en la cual laboro actualmente, por la beca permiso otorgada que hizo posible la realización de mis estudios de Maestría en Ciencias de la Computación, y que me aportaron herramientas para mi superación como docente en UNIDEG.

A los miembros del Sindicato Único de Trabajadores y Empleados de la Educación del Estado de Guanajuato SUTEEEG sección SABES, por haberme seleccionado en su proceso interno para el beneficio mencionado. De manera particular agradezco a su representante Adriana Tovar por su inapreciable apoyo.

Al Tecnológico Nacional de México y al Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) por facilitarme sus instalaciones y las herramientas necesarias para poder realizar mis estudios de maestría en Ciencias de la Computación.

De manera muy especial, a mi director de Tesis y maestro, el **Dr. Manuel Mejía Lavalle** por su valioso tiempo, e inapreciable dedicación, orientación, lectura de los trabajos enviados, sugerencias, y sobre todo por su gran voluntad de agilizar los procesos académicos y administrativos para sacar adelante a sus tesis, como lo fue en mi caso.

A mi codirectora de Tesis, la Dra. Andrea Magadán Salazar, por su valioso apoyo, observaciones, sugerencias, orientación, y agilización de procesos administrativos.

A mis revisores de tesis, el Dr. Gerardo Reyes Salgado y el Dr. José Ruiz Ascencio, por su valioso tiempo, observaciones, comentarios y sugerencias para el mejoramiento del documento de tesis.

A todos mis profesores que me impartieron alguna materia de los cuales aprendí mucho, y en general a todo el personal, a docentes y administrativos del CENIDT, en particular a Liliana Mérida Zagal y a Lupita Garrido Rivera por su apoyo en el proceso administrativo.

A mis compañeros del CENIDET con los que compartí materias, charlas, ideas, y que de alguna u otra manera me apoyaron. De manera especial a los compañeros del grupo de IA: Kevin, Irving, Edgar, Sergio, Diego, Moisés, Omar... a Kenia, Rosy, Derrick ...les agradezco su apoyo técnico y agradable compañía durante mi estancia en CENIDET, época de la cual conservo bonitos recuerdos.

A todos los que no mencioné y de los que recibí apoyo.

Resumen

El modelo de Red Neuronal Pulso-Acoplada inspirado en estudios de la corteza visual de mamíferos, ha mostrado una adaptación natural para segmentación de imágenes debido a su naturaleza pulsante, lo que lo acerca más al modelo neuronal biológico. En un mundo donde la mayoría de las técnicas para segmentar y/o detectar bordes utilizan operadores locales sustentados en aproximaciones discretas de la primera y segunda derivada de los niveles de gris de la imagen, se propone el modelo ICM para dar solución al problema de segmentación de imágenes. En este trabajo se experimenta con la Red Neuronal de Intersección Cortical ICM (una de las variantes de las Redes Neuronales Pulso-Acopladas PCNN), como una alternativa para la segmentación de imágenes del cerebro humano, y se realiza un estudio comparativo que involucra diversos métodos de segmentación y métricas de evaluación.

Abstract

The Pulse-Coupled Neural Network model inspired by studies of the visual cortex of mammals, has shown a natural adaptation for image segmentation due to its pulsating nature, which brings it closer to the biological neuron model. In a world where most of the techniques to segment and / or detect edges use local operators based on discrete approximations of the first and second derivatives of the gray levels of the image, the ICM model is proposed to solve the image segmentation problem. In this work, we experiment with the ICM, The Intersecting Cortical Neural Network (one of the variants of the PCNN Pulse-Coupled Neural Networks), as an alternative for the segmentation of images of the human brain, and a comparative study is carried out that involves several segmentation methods and evaluation metrics.

INDICE GENERAL

CAPÍTULO 1 INTRODUCCIÓN.....	1
1.1. <i>Motivación</i>	1
1.2. <i>Descripción del problema</i>	2
1.3. <i>Delimitación del problema</i>	2
1.4. <i>Complejidad del problema</i>	3
1.5. <i>Objetivo general</i>	4
1.6. <i>Objetivos específicos</i>	4
1.7. <i>Alcances del proyecto</i>	5
1.8. <i>Limitaciones del proyecto</i>	5
1.9. <i>Justificación</i>	6
1.10. <i>Metodología de solución</i>	6
1.11. <i>Organización del documento</i>	7
CAPÍTULO 2 MARCO REFERENCIAL.....	8
2.1. <i>Antecedentes Institucionales</i>	8
2.2. <i>Estado del arte</i>	13
2.3. <i>Discusión</i>	33
CAPÍTULO 3 MARCO TEÓRICO.....	37
3.1. <i>Cerebro e Inteligencia Artificial</i>	37
3.2. <i>Inicios de la Neurociencia</i>	38
3.3. <i>El Sistema Nervioso</i>	40
3.4. <i>El cerebro humano</i>	42
3.5. <i>Células nerviosas</i>	45
3.6. <i>Potencial de acción</i>	48
3.7. <i>La membrana neuronal</i>	53
3.8. <i>Modelo matemático neuronal de Hodgkin-Huxley</i>	60
3.9. <i>Modelo matemático neuronal de McCulloch-Pitts</i>	78
3.10. <i>Redes Neuronales Artificiales de primera y segunda generación</i>	84
3.11. <i>Redes Neuronales Artificiales de tercera generación</i>	89
3.12. <i>Segmentación</i>	104
CAPÍTULO 4 MODELO PROPUESTO Y ENTORNO DE EXPERIMENTACIÓN.....	107
4.1 <i>Modelo de Intersección Cortical (ICM)</i>	107
4.2 <i>Algoritmo ICM</i>	108
4.3 <i>Experimentación preliminar</i>	111
4.4 <i>Segmentación con ICM</i>	111
4.5 <i>Base de datos de Imágenes de Resonancia Magnética (MRI)</i>	113
4.6. <i>Métricas Aplicadas</i>	115
4.7. <i>Segmentadores seleccionados</i>	119
4.8. <i>Plataforma de Experimentación</i>	129
4.9. <i>Discusión</i>	129
CAPÍTULO 5 EXPERIMENTACIÓN Y RESULTADOS.....	130
5.1 <i>Segmentación con ICM y Canny</i>	130
5.2 <i>Segmentación ICM bajo la Métrica Entropía Cruzada</i>	136

5.3 Segmentación ICM bajo la Métrica Entropía (H)	140
5.4 Segmentación ICM bajo la Métrica Contraste del Nivel de Gris (GC).....	143
5.5 Análisis de Resultados por Métrica Aplicada	145
5.6 Distancia promedio entre resultados de ICM y el resto de segmentadores.....	148
5.7. Muestras de Segmentaciones Realizadas	151
5.8. Discusión.....	156
CAPÍTULO 6 CONCLUSIONES.....	157
6.1. Logros alcanzados.....	157
6.2. Aportaciones.....	164
6.3. Productos y participaciones	164
6.4. Conclusiones y trabajo futuro	165
BIBLIOGRAFÍA.....	167
ANEXOS	175
Anexo A. Constancia Poster: Jornada de Ciencia, Tecnología e Innovación Tecnológica 2019.....	175
Anexo B. Poster: Jornada de Ciencia, Tecnología e Innovación Tecnológica 2019	176
Anexo C. Constancia Artículo CIINDET 2019.....	177
Anexo D. Evidencia Artículo CIINDET 2019	178
Anexo D. Reconocimiento Ponencia Artículo Escuela de Inteligencia Artificial y Robótica (SAIBOT 2019).	179
Anexo E. Evidencia Artículo SAIBOT 2019.....	180

Índice de Figuras

Figura 1.1. Delimitación del problema específico	2
Figura 1.2. Diagrama de la metodología de solución de tesis	7
Figura 2.1. Resultados de la evaluación en segmentación de bordes, y porcentaje de similitud mediante métrica <i>PixToPix</i> para <i>Cameraman</i> [Cárdenas, 20015].....	9
Figura 2.2. Ejemplo de firmas obtenidas con SCM para los casos de montaña [Zarate, 2015] ...	10
Figura 2.3. Comparación de las propiedades neuro-computacionales de los modelos analizados. <i>Which Model to Use for Cortical Spiking Neurons?</i> [Izhikevich, 2004].....	15
Figura 2.4. Comparación de resultados de las variantes ICM vs técnicas tradicionales Canny y Sobel en ambos formatos de imágenes PET-RM1 Y PET-RM2. [Cárdenas, 2014]	17
Figura 2.5. Diagrama a bloques de la arquitectura <i>NeuCube</i> con sus módulos principales para un caso de estudio sobre fMRI.....	19
Figura 2.6. Memoria asociativa con clases I y II del modelo de Izhikevich [Osawa, 2015]	21
Figura 2.7. Serie de Tablas de resultados de la experimentación para probar la robustez de la capacidad de clasificación de una red neuronal pulsante que recibe entradas con ruido [Yang, 2015].	22
Figura 2.8. Flujo de trabajo esquemático del aprendizaje automático supervisado [Lee, 2017] ..	25
Figura 2.9. Comparación de segmentación de imágenes [Ma, 2004].....	26
Figura 2.10. Comparación visual de segmentación de superpíxeles en $K = 400$	28
Figura 2.11. Ejemplo de la segmentación PCNN heterogénea: a) imagen original; b) Histograma de la imagen original; c) Resultados de la segmentación de PCNN heterogénea.	33
Figura 3.1. Uno de los dibujos de la circuitería del cerebro de Ramón y Cajal [Bear, 2016] [Gerstner-Kistler, 2014].....	39
Figura 3.2. A) Sistema Nervioso formado por el SNC y el SNP. B) Mapa de Brodmann de la citoarquitectura de la corteza cerebral humana. Ejemplo, áreas: 3, 1 y 2) corteza somatosensorial primaria, 4) Corteza motora primaria [Bear, 2016]	41
Figura 3.3. A) Las 7 partes principales del Sistema Nervioso Central [Kandel, 2013]. B) Lóbulos cerebrales [Bear, 2016]	42
Figura 3.4. A) hemisferios cerebrales, B) funciones especializadas del cerebro [Bear, 2016]	44
Figura 3.5. Representación esquemática básica del sistema nervioso con el cerebro como centro de control [Haykin, 2009] [Arbib, 1987]	45
Figura 3.6. Partes de la neurona. Neuronas presinápticas y postsinápticas [Kandel, 2013]	46
Figura 3.7. Tipos de neuronas según su función. [Kandel, 2013]	47
Figura 3.8. Este trazo histórico es el primer registro intracelular de la forma de un potencial de acción a lo largo del axón gigante de calamar obtenido por Hodgkin y Huxley en 1939, en sus estudios rumbo al modelo matemático de la neurona biológica. La escala vertical está en	

milivoltios, y la escala horizontal en pulsos de tiempo [Kandel, 2013] [Hodgkin-Huxley, 1939]	49
Figura 3.9. Una Neurona Modelo tiene cuatro Componentes involucrados en la Generación de Potenciales de Acción [Kandel, 2013].....	50
Figura 3.10. Variedad de patrones de potenciales de acción en neuronas del cerebro humano [Kandel, 2013]	52
Figura 3.11. Algunos componentes del interior de la neurona. A) [Kiernan, 2014], B) [Bear, 2016]	54
Figura 3.12. Membrana neuronal compuesta por una doble capa de fosfolípidos y diversos canales iónicos. Alrededor de los iones se forman “aguas de hidratación” [Kandel, 2013].....	56
Figura 3.13. En el potencial de reposo se crea una separación de carga a cada lado de la membrana en forma de nubes finas de iones positivos y negativos	58
Figura 3.14. Una pequeña despolarización provoca una corriente capacitiva I_c y una corriente de fuga I_l que conforman la corriente de membrana total I_m [Kandel 2013]	61
Figura 3.15. Corriente total en respuesta a una gran despolarización [Kandel 2013]	61
Figura 3.16. Corrientes individuales de sodio I_{Na} y potasio I_K después de restar I_c e I_l obtenidas con la aplicación de la tetrodotoxina (TTX), y el tetraetilamonio (TEA) [Kandel 2013]	62
Figura 3.17. Comportamientos individuales de las corrientes de sodio I_{Na} y potasio I_K	63
Figura 3.18. Representación eléctrica de un canal iónico.....	65
Figura 3.19. Fuerzas eléctricas y químicas que contribuyen al paso de corriente través de un canal iónico [Kandel, 2013].....	66
Figura 3.20. Circuito eléctrico equivalente base del modelo matemático de la neurona. Incluye cuatro tipos de corrientes iónicas y bombas de $Na^+ + K^+$ [Kandel 2013].....	67
Figura 3.21. Circuito eléctrico equivalente simplificado que incluye la configuración a voltaje fijo (voltage-clamp) utilizado por Hodgkin y Huxley en su investigación [Kandel, 2013]	68
Figura 3.22. La despolarización induce en los canales de sodio tres estados diferentes: reposo, activados o inactivados [Kandel, 2013]	69
Figura 3.23. Respuesta de los canales de Na^+ y K^+ a una despolarización prolongada [Kandel. 2013]	70
Figura 3.24. Circuito eléctrico general equivalente base del modelo matemático de la neurona. Incluye cuatro tipos de corrientes iónicas [Izhikevich, 2007]	71
Figura 3.25. Circuito eléctrico equivalente [Izhikevich, 2007]	72
Figura 3.26. Representación de las Función $m \infty V$ y $h \infty V$. La región sombreada representa una corriente notable y persistente [Izhikevich, 2007]......	74
Figura 3.27: Comportamiento de: A) Funciones de activación e inactivación de estado estable. B) Constantes de tiempo dependientes de voltaje en el modelo Hodgkin-Huxley [Izhikevich, 2007]	75
Figura 3.28. Potencial de acción en el modelo Hodgkin-Huxley [Izhikevich, 2007].....	76

Figura 3.29: Ciclo de retroalimentación positiva y negativa que resultan en un comportamiento regenerativo en las neuronas [Izhikevich, 2007]	77
Figura 3.30. Esquema de la neurona de McCulloch y Pitts [Rojas, 2001]	78
Figura 3.31. Diagramas de redes McCulloch y Pitts donde se muestran sus tipos de conexiones lógicas [McCulloch-Pitts, 1943] [Piccinini, 2004][Kleene, 1956]	82
Figura 3.32. Red neuronal de McCulloch y Pitts que explica la ilusión de calor [McCulloch-Pitts, 1943] [Piccinini, 2004]	83
Figura 3.33. Modelo de una neurona artificial [Haykin, 2009]	86
Figura 3.34. Función escalón [Haykin, 2009].....	87
Figura 3.35. Función Sigmoide Logística [Haykin, 1999]	88
Figura 3.36. A) Dinámica de la corriente I , la variable de activación m y la variable de inactivación h en el experimento a voltaje fijo.....	94
Figura 3.37. Dinámica de disparo de pulsos de las neuronas de tipo excitatorio [Izhikevich, 2003]	100
Figura 3.38. Dinámica de disparo de pulsos de las neuronas de tipo inhibitorio [Izhikevich, 2003]	100
Figura 3.39. Dinámica de disparo de pulsos de las neuronas de tipo inhibitorio [Izhikevich, 2003]	101
Figura 3.40. Modelo neuronal de Eckhorn [Lindblad, 2005]	103
Figura 3.41. Representación esquemática de una neurona PCNN [Lindblad, 2005] [Aguilar, 2019]	103
Figura 3.42. Ejemplo de Segmentación. a) Imagen original, b) Imagen Segmentada [Ma, 2010]	105
Figura 4.1. Desarrollo del estado interno de una neurona ICM [Ortiz, 2017] [Aguilar, 2019]..	107
Figura 4.2. Relación uno a uno entre los pixeles de una imagen y neuronas ICM [Xiao-Bo, 2008]	109
Figura 4.3. Diagrama de flujo del algoritmo ICM	110
Figura 4.4. Segmentación experimental con ICM. Imagen JPG de Lena en escala de grises (225x225 pixeles)	111
Figura 4.5. Salidas de una Red Pulsante para nueve épocas (efecto “auto onda”) [Ma, 2010].	111
Figura 4.6. Actividad del estado interno de una neurona del tipo PCNN [Zhan, 2016] [Lindblad, 2005]	112
Figura 4.7. Muestras de imágenes de las secuencias ponderadas T1, T2 y PD (<i>Proton Density</i>) [Aguilar, 2028] [<i>BrainWeb</i> SBD]	114
Figura 4.8. Comparación de las gráficas de Entropía utilizando logaritmos de diferentes bases	117
Figura 4.9. Interpretación topográfica de una imagen en la segmentación <i>Watershed</i> , con colinas y valles (cuencas de captación) [Hahn, 2005]	125

Figura 4.10. En un escenario de inundación, el agua proveniente de cuencas vecinas se fusionaría a niveles de inundación progresiva, se construyen diques o watersheds [Hahn, 2005].....	126
Figura 5.1. Diagrama de flujo del algoritmo ICM con mecanismo de selección de mejor imagen segmentada.....	131
Figura 5.2. De izquierda a derecha: Imagen original, imágenes segmentada mediante ICM, y seleccionadas mediante H y GC respectivamente. Segmentación mediante Canny. En el caso de ICM, los valores máximos obtenidos en ambas métricas fueron: $H = 0.146717$ y la mejor imagen segmentada ocurre en la época 21. $GC = 0.571429$ y ocurre en la época 21	132
Figura 5.3. Se muestra la entrada de una imagen del cerebro humano a ICM y Canny, con los valores de la H y GC para ambos, así como las imágenes de salida correspondientes	133
Figura 5.4. Algunas de las imágenes segmentadas mediante Canny de OpenCV	134
Figura 5.5. Comparación de la Entropía para 150 imágenes aplicando ICM y Canny.....	134
Figura 5.6. Comparación del Contraste del Nivel de Gris para 150 imágenes aplicando ICM y Canny	135
Figura 5.7. De izquierda a derecha: Imagen original, imágenes segmentada mediante ICM, y seleccionadas mediante H y GC respectivamente. Segmentación mediante Canny. En el caso de ICM, los valores máximos obtenidos en ambas métricas fueron: $H = 0.9999$. $GC = 0.8563$. Para Canny, $H = 0.9559$ y $GC = 0.2417$	135
Figura 5.8. Comparación de la Entropía Cruzada para 150 imágenes aplicando segmentación ICM y Canny.....	137
Figura 5.9. Algunas de las imágenes segmentadas mediante Sobel de OpenCV	137
Figura 5.10. Comparación de la Entropía Cruzada para 150 imágenes aplicando segmentación ICM y Sobel.....	138
Figura 5.11. Algunas de las imágenes segmentadas mediante <i>Watershed</i> de OpenCV	138
Figura 5.12. Comparación de la Entropía Cruzada para 150 imágenes aplicando segmentación ICM y Watershed.....	139
Figura 5.13. Algunas de las imágenes segmentadas mediante LSC de OpenCV	139
Figura 5.14. Comparación de la Entropía Cruzada para 150 imágenes aplicando segmentación ICM y LSC.....	140
Figura 5.15. Comparación de la Entropía para 150 imágenes aplicando segmentación ICM y Sobel	141
Figura 5.16. Comparación de la Entropía para 150 imágenes aplicando segmentación ICM y <i>Watershed</i>	142
Figura 5.17. Comparación de la Entropía para 150 imágenes aplicando segmentación ICM y LSC	142
Figura 5.18. Comparación del Contraste del Nivel de Gris para 150 imágenes aplicando segmentación ICM y Sobel.....	143
Figura 5.19. Comparación del Contraste del Nivel de Gris para 150 imágenes aplicando segmentación ICM y <i>Watershed</i>	144

Figura 5.20. Comparación del Contraste del Nivel de Gris para 150 imágenes aplicando segmentación ICM y LSC.....	144
Figura 5.21. Comparativa de segmentación entre la Red Neuronal ICM, y los diferentes segmentadores aplicando la métrica de Entropía Cruzada (CE).....	145
Figura 5.22. Comparativa de segmentación entre la Red Neuronal ICM, y los diferentes segmentadores aplicando la métrica de Entropía (H)	146
Figura 5.23. Comparativa de segmentación entre la Red Neuronal ICM, y los diferentes segmentadores aplicando la métrica de Contraste del Nivel de Gris (GC).....	147
Figura 5.24. Comparativa de segmentación entre la Red Neuronal ICM, y los diferentes segmentadores aplicando la métrica de <i>Overall Merit</i> (OM)	148
Figura 5.25. Distancia promedio entre los resultados de ICM y el resto de segmentadores bajo la métrica Entropía (H)	149
Figura 5.26. Distancia promedio entre los resultados de ICM y el resto de segmentadores bajo la métrica Nivel de Gris (GC).....	149
Figura 5.27. Distancia promedio entre los resultados de ICM y el resto de segmentadores bajo la métrica Entropía Cruzada (CE).....	150
Figura 5.28. Distancia promedio entre los resultados de ICM y el resto de segmentadores bajo la métrica <i>Overall Merit</i> (OM)	150
Figura 5.29. Ejemplos de segmentación. Métrica aplicada: Contraste del Nivel de Gris (GC)	151
Figura 5.30. Ejemplos de segmentación. Métrica aplicada: Contraste del Nivel de Gris (GC)	151
Figura 5.31. Ejemplos de segmentación. Métrica aplicada: Contraste del Nivel de Gris (GC)	152
Figura 5.32. Ejemplos de segmentación. Métrica aplicada: Contraste del Nivel de Gris (GC)	152
Figura 5.33. Ejemplos de segmentación. Métrica aplicada: Contraste del Nivel de Gris (GC)	152
Figura 5.34. Ejemplos de segmentación. Métrica aplicada: Contraste del Nivel de Gris (GC)	152
Figura 5.35. Ejemplos de segmentación. Métrica aplicada: Contraste del Nivel de Gris (GC)	153
Figura 5.36. Ejemplos de segmentación. Métrica aplicada: Entropía (H)	153
Figura 5.37. Ejemplos de segmentación. Métrica aplicada: Entropía (H)	153
Figura 5.38. Ejemplos de segmentación. Métrica aplicada: Entropía (H)	153
Figura 5.39. Ejemplos de segmentación. Métrica aplicada: Entropía (H)	154
Figura 5.40. Ejemplos de segmentación. Métrica aplicada: Entropía (H)	154
Figura 5.41. Ejemplos de segmentación. Métrica aplicada: Entropía (H)	154

Figura 5.42. Ejemplos de segmentación. Métrica aplicada: Entropía (H)	154
Figura 5.43. Ejemplos de segmentación. Métrica aplicada: Entropía Cruzada (CE)	155
Figura 5.44. Ejemplos de segmentación. Métrica aplicada: Entropía Cruzada (CE)	155
Figura 5.45. Ejemplos de segmentación. Métrica aplicada: Entropía Cruzada (CE)	155
Figura 5.46. Ejemplos de segmentación. Métrica aplicada: Entropía Cruzada (CE)	155
Figura 5.47. Ejemplos de segmentación. Métrica aplicada: Entropía Cruzada (CE)	156
Figura 5.48. Ejemplos de segmentación. Métrica aplicada: Entropía Cruzada (CE)	156

Índice de Tablas

Tabla 2.1: Comparativa de las bases de datos académicas [Hernández, 2017]	11
Tabla 2.2. Comparación con trabajos del Estado del Arte. [Morales, 2018].....	12
Tabla 2.3 Evaluación SSIM [Aguilar, 2019]	13
Tabla 2.4. Comparación de algoritmos de entrenamiento [Thakur, 2009]	16
Tabla 2.5. Aplicación de las Redes Neuronales Pulsantes en el Reconocimiento de Patrones y Análisis de Imágenes [Matadamas,2014]	18
Tabla 2.6. Clasificación de patrones mediante el uso de una red neuronal pulsante [Hernández, 2016]	23
Tabla 2.7. Estudios con Aprendizaje Automático sobre imágenes de EVC [Lee, 2017]	24
Tabla 2.8. Métricas de rendimiento de los algoritmos de segmentación de superpíxeles en $K =$ 400.....	28
Tabla 2.9. AMR y AUE promedio, rangos promedio y distribución de rango para cada algoritmo evaluado	30
Tabla 2.10. Tiempo de procesamiento de imágenes [Kornilov, 2018].....	31
Tabla 2.11. Relación de los trabajos presentados dados en forma sintética	33

Capítulo 1 Introducción

1.1. Motivación

Cada vez más la Inteligencia Artificial (IA) está ganando interés para la solución de problemas en muchos campos de aplicación incluida la medicina. La Enfermedad Vasculat Cerebral (EVC) es una de esas áreas de aplicación de la IA cuya finalidad es mejorar la precisión del diagnóstico médico y la calidad de atención del paciente, y que eventualmente converja a un cuidado personalizado de éste, lo que tiende a llamarse medicina de precisión.

La imagen cerebral es el factor clave en el manejo de la EVC dado que forma la base para numerosas decisiones clínicas complejas, y por lo mismo, es un tema atractivo para el empleo de técnicas de IA [Lee, 2017].

Una predicción acertada del diagnóstico médico mencionado, apoyado en técnicas de IA, ayudaría a reducir los costos de los recursos destinados a servicio médico, errores médicos, tiempo, así como la reducción de costo en el servicio lo cual impactaría en el robustecimiento de la atención médica [Thakur, 2009].

Se han utilizado muchas técnicas de IA para el procesamiento, segmentación y clasificación de imágenes del cerebro humano con diferentes propósitos de estudio, y aunque estas técnicas están todavía en su infancia en el campo de la medicina, son aplicadas con entusiasmo al análisis de imágenes médicas [Lee, 2017].

Las Redes Neuronales Pulso Acopladas (PCNN) o Redes Neuronales de tercera generación presentan una perspectiva alterna de aplicación en el área de Inteligencia Artificial, y más específicamente en procesamiento, segmentación y clasificación de imágenes del cerebro humano dentro del dominio de la Visión Artificial, como lo muestran los trabajos realizado por investigadores en general, y dentro del CENIDET, lo que muestra que las PCNN siguen siendo objeto de estudio, precisamente porque, hasta donde se hizo la revisión del estado del arte, hay todavía campos no explorados totalmente para la aplicación de este paradigma de red neuronal, como lo es el campo de la medicina.

1.2. Descripción del problema

En este trabajo se realiza un estudio centrado en el análisis y desarrollo de una Red Neuronal Pulso-Acoplada (PCNN), que, dado su procesamiento paralelo, y debido a que es un paradigma cercano al modelo neuronal biológico, la hacen adaptarse de manera natural al procesamiento de imágenes, por lo cual, se experimenta como método alternativo para dar solución al problema de segmentación de imágenes, cuyo propósito es la segmentación de imágenes digitales del cerebro humano, que podría contribuir en la toma de decisiones importantes en el ámbito médico.

1.3. Delimitación del problema

Dentro del campo de las ciencias, la solución de un problema implica el uso de un sin número de herramientas de diferentes disciplinas que dificultan su delimitación exacta, pero de manera general, en este caso, la problemática a resolver se encuentra dentro del ámbito de la Inteligencia Artificial, y forma parte tanto del dominio de la Visión Artificial, como del campo de las Redes Neuronales Artificiales en general, y de manera particular dentro de las Redes Neuronales Pulso-Acopladas, en un compartimento denominado segmentación de Imágenes, que comprende la segmentación de imágenes digitales del cerebro humano, que es finalmente el problema a resolver (la delimitación de esta problemática se representa de manera aproximada en la Figura 1.1).

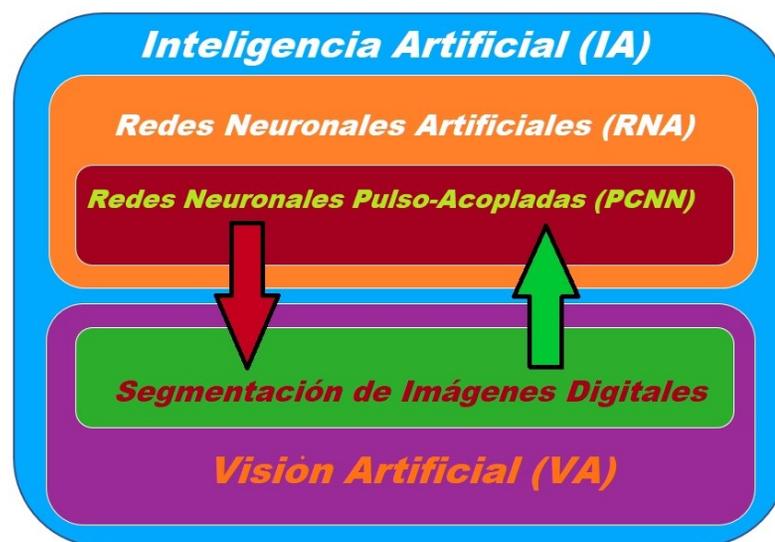


Figura 1.1. Delimitación del problema específico

Es decir, en este trabajo se pretende utilizar el paradigma de las Redes Neuronales Pulso Acopladas como un medio para la segmentación de Imágenes digitales del Cerebro Humano, apoyado en un estudio comparativo con otros segmentadores y métricas de evaluación, cuyos resultados pudieran contribuir a la toma de decisiones de expertos en el área médica.

1.4. Complejidad del problema

Existen diferentes puntos o momentos a lo largo del proyecto con algún tipo y nivel de complejidad, de manera que la complejidad del problema es la suma correspondiente de cada punto del proyecto. Primeramente, se debe tener una idea general del proyecto como un todo, con cada una de sus partes componentes. Entre ellas, el primer paso es llegar a un nivel de comprensión adecuada del modelo matemático de la red neuronal pulso-Acoplada, para tener una idea lo más clara posible de cada una de las variables y parámetros involucradas, y la función que desempeña cada parte componente del modelo matemático elegido. Para esto, se debe revisar el modelo neuronal biológico y el modelo matemático correspondiente, pasando por la teoría de las Redes Neuronales Artificiales en general.

Sustentados en el hecho de que se va a trabajar con imágenes digitales del cerebro humano, es necesario tener conocimiento sobre conceptos y técnicas relacionadas con el procesamiento de imágenes y problemáticas involucradas a resolver, dentro del dominio de la Visión Artificial (VA), y hacer frente a contratiempos o imprevistos relacionados con la adquisición y preparación de las imágenes digitales médicas para su procesamiento.

El análisis y desarrollo computacional del paradigma de Red Neuronal Pulsante, conforma una de las partes más importantes a resolver dentro del proyecto, y por lo mismo, es aquí donde aumenta de complejidad, porque se deben poner a prueba muchos de los elementos estudiados y relacionarlos dentro de un sistema computacional. En este punto del problema, cuando ya se cuenta con las imágenes digitales adecuadas, comienza el verdadero entrenamiento de la red, así como el proceso fuerte de experimentación, donde pueden necesitarse ajustes computacionales, ajustes en los parámetros de la red, valoración de resultados etc. Los resultados

obtenidos son comparados con los resultados dados por otros segmentadores, bajo diferentes métricas de evaluación, seleccionados ad hoc.

Se puede concluir que la complejidad del problema reside en el hecho de dotar a la Red Neuronal de la habilidad para segmentar de manera experta imágenes digitales del cerebro humano, trabajando de forma alternativa como un sistema de Visión Artificial (VA), conocimiento que posteriormente pudieran servir de apoyo para discriminar o detectar lesiones en imágenes digitales del cerebro humano.

1.5. Objetivo general

Analizar, experimentar y evaluar la RNA tipo *Pulse-Coupled Neural Network* (PCNN) en el dominio de la Visión Artificial para la segmentación de imágenes digitales del cerebro humano cuyos resultados pueden ser la entrada a una herramienta auxiliar en el área médica.

1.6. Objetivos específicos

1. Analizar y desarrollar el paradigma de Red Neuronal Pulso-Acoplada en forma computacional para el proceso de segmentación de imágenes digitales del cerebro humano.
2. Definir casos de prueba y validación en el dominio de Visión Artificial, que sean indicadores del proceso adecuado de segmentación de la Red.
3. Seleccionar por lo menos una base de datos de imágenes digitales del cerebro humano, para el proceso de segmentación de imágenes para utilizarse en estudio comparativo.
4. Realizar un estudio comparativo para determinar el desempeño del paradigma de Red Neuronal Pulso-Acoplada como segmentador de imágenes digitales del cerebro humano, con algoritmos tradicionales de segmentación de imágenes sugeridos o reportados en la literatura.
5. Aplicar métricas de evaluación de desempeño de los diferentes algoritmos segmentadores involucrados en el estudio comparativo.
6. Realizar un análisis de resultados.

1.7. Alcances del proyecto

1. Experimentar con bases de datos de Imágenes Resonancia Magnética (MRI) del cerebro humano encontradas en la comunidad de Visión Artificial (al menos una).
2. Realizar el estudio comparativo por lo menos con tres algoritmos tradicionales para la segmentación de imágenes sugeridos o encontrados en la comunidad de Visión Artificial.
3. Realizar el estudio comparativo aplicando por lo menos tres métricas sugeridas o encontrados en la comunidad de Visión Artificial, para evaluar el proceso de segmentación de imágenes.
4. El estudio comparativo no busca mejorar resultados, sino investigar el desempeño de la PCNN en el campo de la segmentación de imágenes, a la luz de las diferentes métricas aplicadas a los algoritmos segmentadores seleccionados, independientemente del tipo y función del algoritmo segmentador.
5. El paradigma de Red Neuronal Pulso-Acoplada en estudio es el Modelo de Intersección Cortical (ICM).

1.8. Limitaciones del proyecto

1. Las métricas y algoritmos utilizados en el estudio comparativo de segmentación de imágenes del cerebro humano se realizarán utilizando software de código libre y/o herramienta Opencv.
2. Realizar el estudio comparativo utilizando imágenes digitales del cerebro humano tal como se encuentran en la literatura, sin realizar modificaciones sustanciales como remoción de cráneo o uso de *ground truth*.
3. Realizar el estudio comparativo utilizando imágenes digitales del cerebro humano sin ruido ni anomalías.
4. Realizar el estudio comparativo utilizando imágenes digitales del cerebro humano en escala de grises.
5. El número de imágenes procesadas está limitado por el número de imágenes de la base de datos seleccionada, tomando en cuenta la capacidad del equipo de cómputo utilizado.

6. El tipo de métricas aplicadas, así como el tipo de algoritmos segmentadores utilizados en el estudio comparativo serán seleccionados exclusivamente por el comité de tesis, independientemente de los resultados que se obtengan.
7. El tiempo de procesamiento en este trabajo no es relevante.

1.9. Justificación

Este proyecto tiene como finalidad, ahondar en el estudio de la PCNN en el campo de la segmentación de imágenes, para lo cual, se propone como eje central la realización de un Estudio Comparativo inédito entre la Red Neuronal Pulso-Acoplada: Modelo Neuronal de Intersección Cortical (ICM) y algoritmos tradicionales del campo de la segmentación de imágenes digitales del cerebro humano. El proyecto está fundamentado en la investigación del estado del arte, el cual muestra que hasta donde se ha investigado, las Redes Neuronales Pulso-Acopladas pueden ser todavía un terreno con mucho potencial de aplicación en el campo de la medicina, específicamente, en la segmentación de imágenes digitales del cerebro humano.

1.10. Metodología de solución

La metodología de solución para el proyecto de tesis se puede resumir en las siguientes fases (ver Figura 1.2):

1. **Fase I.** Marco Teórico y Estado del Arte. Comprende el Estudio de los fundamentos biológicos y computacionales de las redes RNA tradicionales y Pulsantes, sobre todo, investigación del estado del arte de éstas últimas en el dominio de Visión Artificial en el área de segmentación de imágenes.
2. **Fase II.** Desarrollo. Análisis y desarrollo de la Red Neuronal Pulso-Acoplada en el campo de segmentación de imágenes.
3. **Fase III.** Experimentación. Experimentar con la Red Neuronal Pulso-Acoplada con la base de datos de imágenes digitales del cerebro humano seleccionada previamente.
4. **Fase IV.** Evaluación. Realizar Estudio Comparativo con los algoritmos segmentadores y métricas seleccionadas. Finaliza la fase con un Análisis de Resultados.
5. **Fase V.** Terminación. Redactar el proyecto de tesis.

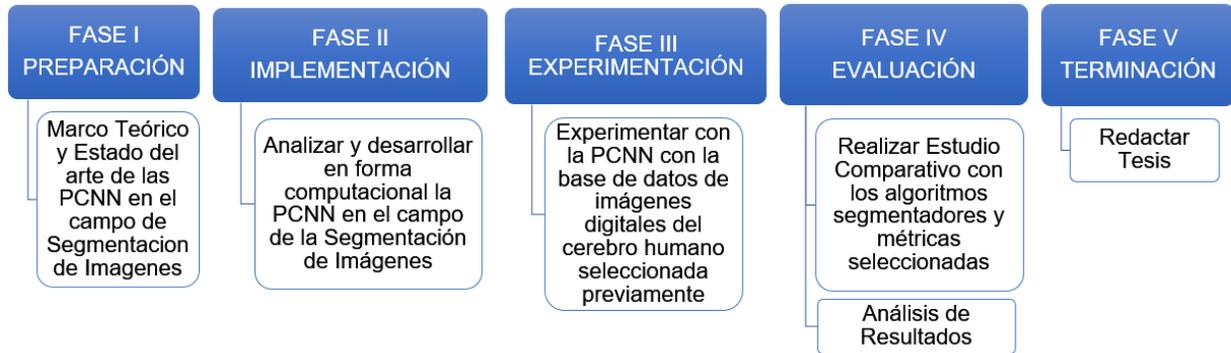


Figura 1.2. Diagrama de la metodología de solución de tesis

1.11. Organización del documento

La investigación de este trabajo de tesis está organizada en capítulos, distribuidos de la siguiente manera: El presente capítulo (Capítulo 1), muestra el aparato que sustenta todo el trabajo posterior, como son los objetivos, alcances, limitaciones y metodología de solución, entre otros. El Capítulo 2: Marco Referencial, versa sobre el estado actual del campo en estudio. En el Capítulo 3: Marco Teórico, se estudian los fundamentos teóricos del campo de estudio. En el Capítulo 4: Modelo Propuesto y Entorno de Experimentación se ubica al lector sobre los elementos empleados en el entorno de experimentación, y se estudia, analiza y desarrolla el modelo de PCNN objeto de estudio en segmentación de imágenes. En el Capítulo 5: Evaluación y Resultados se desarrolla la experimentación realizada hasta culminar en la evaluación del Estudio Comparativo y presentar resultados. En el Capítulo 6: Conclusiones, se dan las conclusiones del trabajo de tesis

Capítulo 2 Marco Referencial

En este capítulo se analizan los trabajos más relevantes relacionados con el tema de investigación, tanto Institucionales (dentro del CENIDET), como investigaciones en general encontradas en el estado del arte (dentro y fuera del CENIDET), enmarcados principalmente dentro del campo de las Redes Neuronales Pulso-Acopladas (PCNN).

Al final se muestra una clasificación en tabla de los trabajos, presentados en las categorías: Antecedentes Institucionales, y del estado del arte en general, y se dan las principales observaciones al respecto.

2.1. Antecedentes Institucionales

En esta sección se hace una revisión de los principales trabajos realizados dentro del Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET), en los cuales se ha hecho uso de las Redes Neuronales Pulso-Acopladas dentro del campo de la segmentación de imágenes digitales del cerebro humano, principalmente.

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

En esta tesis se utilizan las Redes Neuronales Pulso Acopladas PCNN, ICM y variantes para estudios de segmentación de imágenes; bordes y regiones, donde para la primera se utilizan las métricas *Pixel Correspondence Metric* (PCM) y *PixToPix*, y para la segunda, Entropía y Entropía Cruzada. Se utilizan algoritmos expofeso para el procesamiento de información, y presentar el estudio comparativo de manera gráfica y en tablas, incluyendo los paradigmas clásicos Canny y Sobel, y mediante segmentación manual. Los resultados que se obtienen por parte del paradigma pulsante no son en general superiores a los ya posicionados, pero su desempeño es muy cercano a estos últimos, por lo que sugiere que debe tomar en cuenta el modelo pulsante en la segmentación de imágenes, y seguir investigando en esta dirección para mejorar

resultados. Se presentan en la Figura 2.1 los resultados de la evaluación de la segmentación de bordes (gráfica de barras color azul), y porcentaje de similitud utilizando la métrica *PixToPix* (gráfica de barras en colores verde, azul y morado).

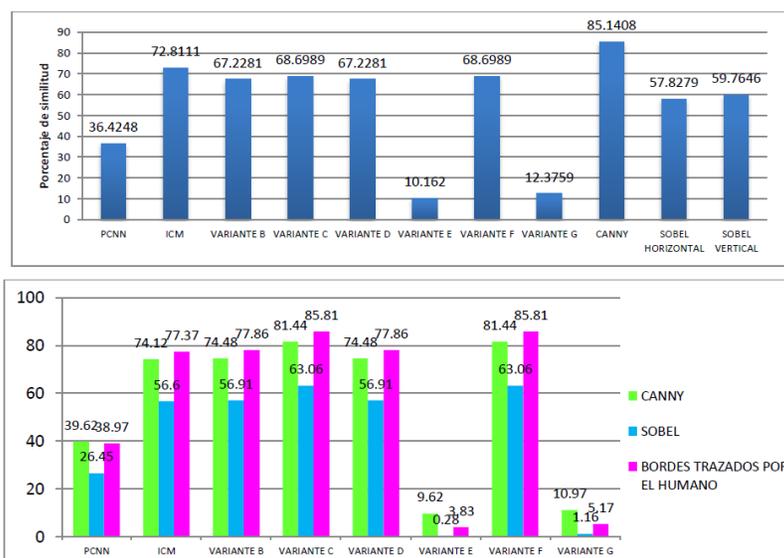


Figura 2.1. Resultados de la evaluación en segmentación de bordes, y porcentaje de similitud mediante métrica *PixToPix* para *Cameraman* [Cárdenas, 20015]

Extracción de Características de Imágenes Digitales mediante una Red Neuronal Artificial Pulsante [Zárate, 2015]

En este trabajo de tesis se utiliza el paradigma pulsante Red Neuronal Pulso-Acoplada (PCNN) al igual que las variantes ICM (*Intersecting Cortical Model*) y SCM (*Spiking Cortical Model*) para extraer características de diversas imágenes, mediante la aplicación sucesiva de las PCNN para obtener una serie de imágenes binarias pulsantes, a las que les aplica un conteo del número de bits para obtener una serie de tiempo que se supone describirá la imagen, lo que constituye una “firma” de la imagen. Las firmas se sometieron a rotación, escalado, ruido impulsivo y ruido aditivo, con el objetivo de distinguir si las firmas son invariantes, lo cual serviría para identificar imágenes con el mismo contenido semántico, como, por ejemplo: si una variedad de imágenes diferentes de “montañas”, tendrían la misma firma (Figura 2.2).

En este estudio la SCM obtuvo mejores resultados en la generación de firmas, aunque se encontraron discrepancias para considerar las firmas obtenidas invariantes, es decir, que describan completamente un determinado tipo de imágenes.

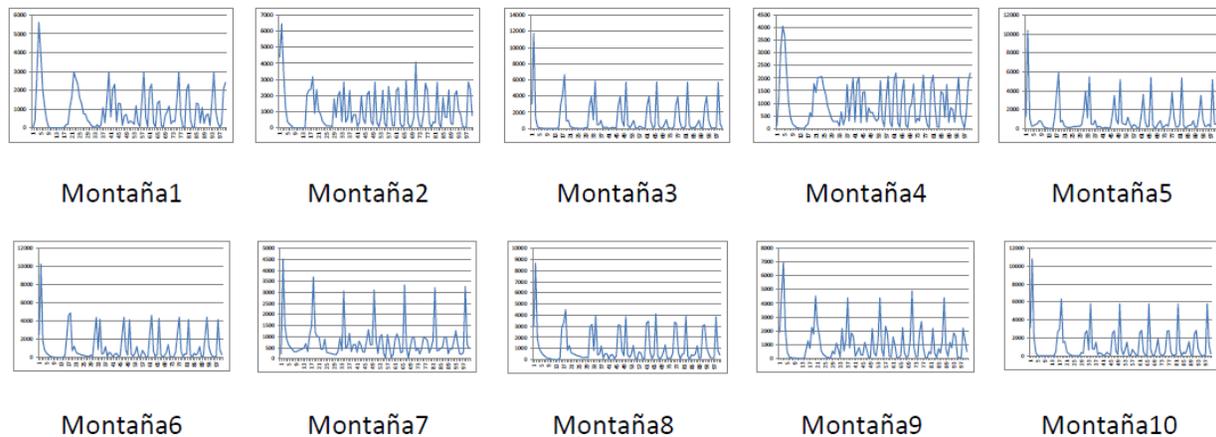


Figura 2.2. Ejemplo de firmas obtenidas con SCM para los casos de montaña [Zarate, 2015]

Detección de Ruido Impulsivo o Gaussiano en Imágenes Monocromáticas Mediante Redes Neuronales Artificiales Pulso-Acopladas [Ortiz, 2017]

En este trabajo de tesis se emplean tres variantes de las Redes Neuronales Pulso-Acopladas (PCNN): ICM (*Intersecting Cortical Model*), SCM (*Spiking Cortical Model*) y el PCNNNI (*PCNN Nule Interconnection*) para la detección y filtrado de ruido impulsivo y gaussiano en imágenes digitales, y se estudia cómo disminuir su efecto mediante los paradigmas pulsantes mencionados. Se realiza un estudio comparativo con las técnicas tradicionales de filtrado de ruido: Filtro Mediana, Filtro Promedio y Filtro Wiener. Aplicados bajo las métricas: NMSE (*Normalized Mean Square Error*), MAE (*Mean Absolute Error*) y PSNR (*Peak Signal-to-Noise Ratio*). Se realiza una aportación mediante la propuesta de dos algoritmos basados en ICM para la eliminación de ruido: El ICM-M, para eliminar el ruido impulsivo por medio de la selección de píxeles ruidosos y el operador de mediana, y el algoritmo ICM-TM para eliminar el ruido gaussiano empleando la matriz de tiempos. El estudio toma en cuenta el tiempo de procesamiento.

Aplicación del Descenso de Gradiente para el Aprendizaje de Neuronas Pulsantes de Izhikevich [Hernández, 2017]

Básicamente experimenta con la red neuronal de Izhikevich de tercera generación, como clasificador, así como experimentación con diferentes algoritmos de

aprendizaje como el algoritmo de evolución diferencial (ED), *Spike Time Dependent Plasticity* (STDP), *Spike-Prop*, el algoritmo supervisado basado en el descenso del gradiente, para la red neuronal de *Izhikevich*. Resuelve los problemas de clasificación binaria AND, OR y XOR, y realiza pruebas con bases de datos *Ionosphere*, *Wisconsin Breast Cancer*, *Iris Data Set*, Pagan y no pagan, así como con bases de datos de imágenes de resonancia magnética del cerebro humano, a las cuales se les aplicó un preprocesamiento, también experimentó con la BD *Semeion* y de patrones ortogonales. La clasificación se realizó con una sola neurona de *Izhikevich*. Muestra que se puede clasificar en un dominio continuo y clasificación binaria. La eficiencia de clasificación es aceptable para un máximo de tres clases. Realiza un estudio comparativo en la clasificación de imágenes de resonancia magnética con red neuronal sigmoidea, como se observa en la Tabla 2.1.

Tabla 2.1: Comparativa de las bases de datos académicas [Hernández, 2017]

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

Segmentación no Paramétrica de Tejidos Cerebrales Mediante una Arquitectura Paralela de Redes Neuronales Convolucionales [Morales, 2018]

Realiza un trabajo de segmentación de tejidos cerebrales mediante una arquitectura de Redes Neuronales Convolucionales (RNC) de aprendizaje profundo, del tipo U-Net, compuesta de cuatro Redes Neuronales Convolucionales paralelas, donde cada una de ellas lleva a cabo una segmentación binaria de un tejido cerebral particular (MB, MG y LCR), y cuya unión forma la segmentación total de la imagen completa. Utiliza dos tipos de repositorios de imágenes cerebrales MRI: *BrainWeb* y *BraTS 2017*, para entrenamiento y validación respectivamente, que con la utilización del entorno de trabajo *Jupyter notebook*, y mediante la programación de *Scripts* en lenguaje *Python* y *C*, se logra la visualización de resultados en forma cualitativa y cuantitativa. Para el correcto uso de los *frameworks Keras* y *TensorFlow*, realiza, tanto un preprocesamiento de las imágenes de entrenamiento, como un aumento de la información, para incrementar el

número de imágenes necesarias para el entrenamiento, dado que este tipo de RN requiere de un gran número de ellas. Se utilizaron las métricas: *Jaccard Similarity Coefficient* (JSC), *Dice Similarity Coefficient* (DSC) y *Area Under the Curve* (AUC), que para el repositorio *BrainWeb* se obtuvieron en promedio, para el resultado de segmentación, JSC: 0.9653, DSC: 0.9438. En el caso de AUC, para el mismo repositorio, MB: 0.90, MG: 0.87, LCR: 0.93, y Fondo: 0.88. Los resultados de manera respectiva para el repositorio *BraTS 2017* fueron, JSC: 0.9692, DSC: 0.9619. MB: 0.93, MG: 0.86, LCR: 0.87, y Fondo: 0.95. Los resultados del estudio comparativo para la muestra de anomalías del repositorio *BraTS 2017* se muestran en Tabla 2.2.

Tabla 2.2. Comparación con trabajos del Estado del Arte. [Morales, 2018]

Método	Resultado de Segmentación
Método propuesto	0.96
FCM (Andermatt <i>et al.</i> , 2017)	0.89
Random Forest (Bharath <i>et al.</i> , 2017)	0.76
SVM (Osman A.F., 2017)	0.81
Ensamble Random Forest (Phophalia and Pradipta., 2017)	0.64

Mejoramiento de la Luminosidad de Imágenes Digitales del Cerebro Humano mediante Redes Neuronales Pulso-Acopladas [Aguilar, 2019]

En este trabajo de tesis se proponen y emplean dos variantes de la Red Neuronal Pulso-Acoplada (PCNN), *Intersecting Cortical Model* (ICM): La ICM-LTM (*Intersecting Cortical Model-Luminance Time Matrix*) y la ICM-LTM2 (*Intersecting Cortical Model-Luminance Time Matrix2*) para mejorar la luminosidad en imágenes digitales del cerebro humano. Para la evaluación de los resultados, se realiza una comparativa con los algoritmos tradicionales: EH (*Ecuación del histograma*), PLT (*Power-Law Transform*) y CLAHE (*Contrast Limited Adaptive Histogram Equalization*), bajo las métricas de calidad: C y SSIM (Structural SIMilarity). Se experimentó con imágenes médicas obtenidas de *BrainWeb* en tres modalidades de estudios, y con imágenes obtenidas del *dataset* BSDS500 (diez imágenes). Las pruebas se realizaron en imágenes en escalas de grises, a las cuales se les aplicó la técnica de degradación: desplazamiento del histograma (diez en total) tanto para valores positivos como negativos en la primera base de datos de imágenes, y un desplazamiento en la segunda, esto con la finalidad de

afectar la luminosidad de las imágenes y obtener imágenes luminosas y oscuras para experimentación. Los modelos implementados presentaron resultados superiores a las técnicas tradicionales, y menor tiempo de procesamiento. En la Tabla 2.3 se muestran parte de los resultados obtenidos al experimentar con imágenes de la base de datos *BrainWeb*, y con la aplicación de la métrica SSIM.

Tabla 2.3 Evaluación SSIM [Aguilar, 2019]

DH	ICM-LTM	ICM-LTM2	EH	PLT	CLAHE
+20	<u>0.71</u>	0.55	<u>0.06</u>	0.28	0.34
+40	<u>0.60</u>	0.44	<u>0.05</u>	0.28	0.32
+60	<u>0.47</u>	0.36	<u>0.05</u>	0.24	0.31
+80	<u>0.38</u>	0.30	<u>0.04</u>	0.24	0.30
+100	<u>0.35</u>	0.27	<u>0.04</u>	0.26	0.28
+120	<u>0.31</u>	0.23	<u>0.04</u>	0.29	0.26
+140	0.31	0.19	<u>0.03</u>	<u>0.33</u>	0.25
Promedio	<u>0.45</u>	0.33	<u>0.04</u>	0.27	0.29

2.2. Estado del arte

En este apartado se hace una revisión de los principales trabajos realizados dentro y fuera del Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET), que representen el estado del arte en del tema de investigación, y en los cuales se ha hecho uso de las Redes Neuronales Pulso-Acopladas y del campo de la segmentación de imágenes digitales del cerebro humano, principalmente.

Image Processing Using Pulse-Coupled Neural Networks [Lindblad, 2005].

Este es un libro pionero que revisa la teoría, aplicaciones y algoritmos de la Red Neuronal Pulso-Acoplada (PCNN) y la variante, el Modelo Neuronal de Intersección Cortical (ICM), paradigmas basados en los modelos biológicos de la corteza visual de mamíferos.

Estudia la PCNN como un algoritmo de red neuronal que produce una serie de pulso-imágenes binarias cuando se estimula con una imagen en escala de grises o una imagen en color. Encuentran que esta red es diferente de lo que generalmente se entendía por Redes Neuronales Artificiales en el sentido de que no se entrena. También encontraron que la PCNN posee capacidades de autoorganización que permitan utilizarla como memoria asociativa, algo inusual para un algoritmo que no se entrena. Debido a

que la PCNN sólo tiene conexiones locales encontraron plausible la implementación en hardware electrónico, así como su uso como herramienta muy poderosa que permitía la exploración en el empleo de aplicaciones de procesamiento de imágenes como: segmentación, extracción de bordes, extracción de texturas, reconocimiento de objetos, aislamiento de objetos, procesamiento de movimiento, supresión de ruido, fusión de imágenes y la implementación electrónica mencionada, lo que hace a este texto una base para estudios posteriores de las PCNN. Para este trabajo se estudiaron principalmente los capítulos 1 y 2 y la parte de segmentación del capítulo 3.

Which Model to Use for Cortical Spiking Neurons? [Izhikevich, 2004]

En este trabajo se analiza la plausibilidad biológica y la eficiencia computacional de algunos de los modelos de neuronas pulsantes más útiles, y se realiza una comparación y contraste de varios modelos de neuronas pulsantes (ver Figura 2.3). Primeramente, se revisan veinte de las características más notables de las neuronas biológicas pulsantes, y se describe la variedad y complejidad de su comportamiento individual en respuesta a pulsos simples de corriente continua, y se observa su potencial de membrana. Estas características son las siguientes: A) *Tonic Spiking*. B) *Phasic Spiking*. C) *Tonic Bursting*. D) *Phasic Bursting*. E) *Mixed Model (Bursting Then Spiking)*. F) *Spike Frequency Adaptation*. G.) Excitabilidad Clase 1. H) Excitabilidad clase 2. I) *Spike Latency*. J) *Subthreshold Oscillations*. K) *Frequency Preference and Resonance*. L) *Integration and Coincidence Detection*. M) *Rebound Spike*. N) *Rebound Burst*. O) *Threshold Variability*. P) *Bistability of Resting and Spiking States*. Q) *Depolarizing After-Potentials*. R) *Accommodation*. S) *Inhibition-Induced Spiking*. T) *Inhibition-Induced Bursting*. Cada una es un tipo de pulso de salida observada.

Los Modelos Neuronales Pulsantes pueden ajustarse para exhibir cada propiedad anterior. Cada uno de ellos puede expresarse en forma de ecuaciones diferenciales ordinarias. Para comparar su costo computacional, se asume que cada modelo escrito como sistema dinámico $\dot{x} = f(x)$, es implementado usando un método de Euler de primer orden, $x(t + \tau) = x(t) + \tau f(x(t))$ con el paso de tiempo de integración fijo τ , elegido para lograr una precisión numérica razonable. En la Figura 2.3, la primera columna

muestra el nombre de cada uno de los Modelos de Neuronas Pulsantes estudiados en este artículo.

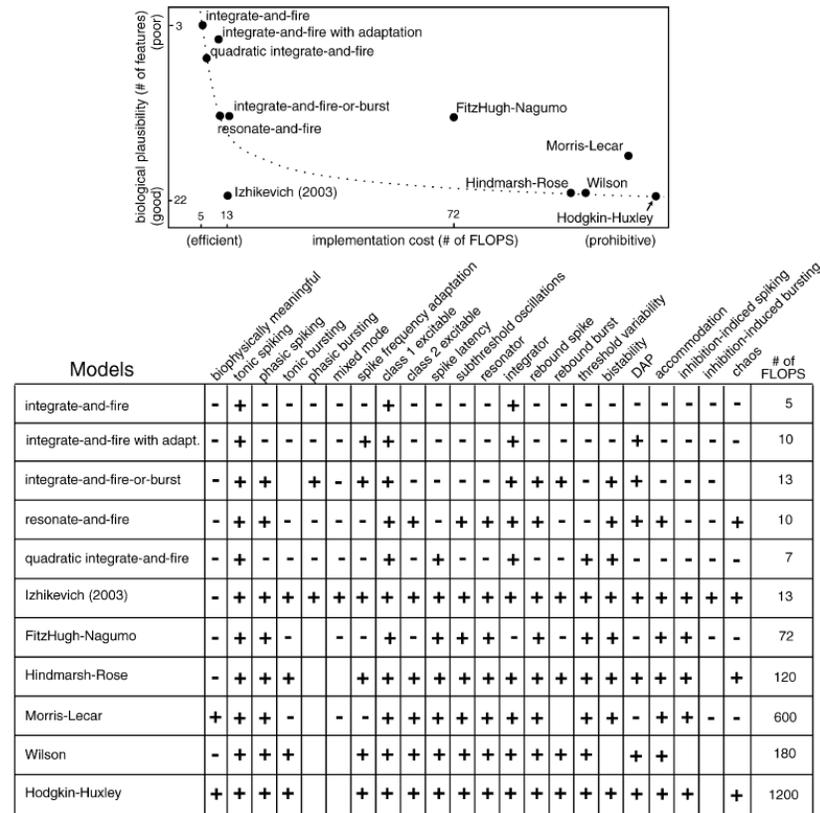


Figura 2.3. Comparación de las propiedades neuro-computacionales de los modelos analizados. *Which Model to Use for Cortical Spiking Neurons?* [Izhikevich, 2004]

En la parte superior de la segunda a la penúltima columna, se muestra cada una de las características observadas en las salidas de las neuronas biológicas. En la última columna se presenta el costo computacional de cada modelo estudiado. Un signo más significa que se puede reproducir la característica correspondiente mediante un ajuste de parámetros del modelo. Uno negativo, que no es posible, o es muy difícil. De todos estos modelos, destaca el Modelo de Izhikevich (2003), el cual puede reproducir todas las características mencionadas, excepto la de la segunda columna que corresponde al “Significado Biofísico”. Además, su costo computacional es uno de los más bajos, (13 FLOPS para simular 1 ms del modelo).

El Modelo Neuronal Pulsante de Izhikevich (2003), es $v' = 0.04v^2 + 5v + 140 - u + I$ con $u' = a(Bv - u)$ con la condición de reinicio **if** $v \geq +30 \text{ mV}$ **Then** $\left\{ \begin{matrix} v \leftarrow c \\ u \leftarrow u + d \end{matrix} \right\}$, v

denota el potencial de membrana y u representa una variable de recuperación de membrana. Después del disparo del Pulso v y u se reinician. Los parámetros a, b, c, d pueden ajustarse para exhibir todos los patrones de disparo. τ debe ser pequeño para lograr precisión numérica. El valor umbral de la neurona modelo está entre -70 y -50 mV, y es dinámico, como en las neuronas biológicas. ¿Cuál de todos estos modelos usar?, depende de las características de investigación. El autor da una explicación más detallada al respecto.

Early Diagnosis of Ischemia Stroke using Neural Network [Thakur, 2009]

Utiliza una metodología no muy elaborada de IA para la detección temprana de la EVC de tipo isquémico, utilizando un modelo de Red Neuronal BP (*Backpropagation*) con alimentación hacia adelante, con diez neuronas en la primera capa, que corresponden a la introducción de una combinación de síntomas físicos y factores de riesgo dados por los pacientes y estandarizados por la *American Stroke Association*. Con veinte neuronas de la capa oculta y una de salida que da la probabilidad de tener trastorno isquémico. Se hicieron estudios comparativos utilizando diferentes algoritmos de entrenamiento para su optimización (ver Tabla 2.4), y se graficaron los resultados de 280 muestras de pacientes con diez combinaciones de síntomas y factores de riesgo, donde se muestran: el número de iteraciones para alcanzar el mínimo error, la curva de rendimiento y una gráfica de regresión que muestra fuerte correlación entre los datos de entrada y los deseados. No utiliza procesamiento de imágenes. Se utilizó un programa escrito en lenguaje MATLAB que, según el estudio, se obtuvo un diagnóstico 99.99% correcto. El algoritmo de entrenamiento LM fue el que dio mejores resultados, según Tabla 2.4 de este trabajo.

Tabla 2.4. Comparación de algoritmos de entrenamiento [Thakur, 2009]
Comparison of Training Algorithms

Training Algorithms	1E-01	1E-02	1E-03	1E-04	1E-05
LM	3	3	5	6	9
GDX	110	176	190	218	269
RP	8	12	13	16	21
CGF	2	18	19	20	21
BFG	4	13	25	29	36

Pulse-Coupled Neural Networks applied to Human Brain Image Processing [Cárdenas, 2014]

En este artículo se realiza una serie de experimentos con un conjunto de variantes del modelo de red neuronal Pulso-Acoplada ICM (*Intersecting Cortical Model*), propuesta en este mismo trabajo, para medir la efectividad de la detección de bordes en dos imágenes del cerebro humano, de origen de Resonancia Magnética Nuclear y Tomografía por Emisión de Positrones (PET-MR1 y PET-MR2). Se compararon las salidas ICM con las salidas obtenidas de dos de los algoritmos más conocidos en el campo de Visión Artificial, como son, Canny y Sobel. Los resultados muestran que las modificaciones propuestas en este trabajo al paradigma ICM, produjeron una mejor detección de bordes que los algoritmos tradicionales mencionados. Ver Figura 2.4.

ICM VARIANT	PERCENT SIMILARITY OF 100 PICTURES	PERCENTAGE OF SIMILARITY OF THE FIRST 30 PICTURES
C	58.36	59.26
F	58.36	59.26
B	57.26	59.74
D	57.26	59.74
A	53.89	58.24
G	51.30	52.04
E	45.78	47.19

1. PET-MR1: ICM vs Canny

ICM VARIANT	PERCENT SIMILARITY OF 100 PICTURES	PERCENTAGE OF SIMILARITY OF THE FIRST 30 PICTURES
C	17.44	19.05
F	17.44	19.05
B	15.08	17.27
D	15.08	17.27
A	13.76	16.43
G	4.35	4.71
E	2.32	2.83

3. PET-MR1: ICM vs Vertical Sobel

ICM VARIANT	PERCENT SIMILARITY OF 100 PICTURES	PERCENTAGE OF SIMILARITY OF THE FIRST 30 PICTURES
C	58.40	55.89
F	58.40	55.89
B	57.50	57.28
D	57.50	57.28
A	54.10	56.03
G	11.44	12.15
E	5.74	7.46

2. PET-MR2: ICM vs Canny

ICM VARIANT	PERCENT SIMILARITY OF 100 PICTURES	PERCENTAGE OF SIMILARITY OF THE FIRST 30 PICTURES
C	18.29	20.01
F	18.29	20.01
B	15.75	18.10
D	15.75	18.10
A	14.37	17.23
G	4.02	4.35
E	1.79	2.33

4. PET-MR1: ICM vs Horizontal Sobel

Figura 2.4. Comparación de resultados de las variantes ICM vs técnicas tradicionales Canny y Sobel en ambos formatos de imágenes PET-RM1 Y PET-RM2. [Cárdenas, 2014]

Aplicación de las Redes Neuronales Pulsantes en el Reconocimiento de Patrones y Análisis de Imágenes [Matadamas,2014]

Utiliza las Redes Neuronales Pulsantes de tercera generación, específicamente el modelo de Izhikevich aplicado al procesamiento de imágenes y reconocimiento de patrones, apoyado por el algoritmo de aprendizaje no supervisado Evolución Diferencial (EV) del área de la computación evolutiva. En este trabajo de tesis, se realizan una serie de experimentos que involucran diferentes arquitecturas de la red neuronal de Izhikevich.

Para el reconocimiento de patrones se utiliza una arquitectura de tres capas: Entrada, Oculta y Salida. La capa oculta tiene un número de neuronas equivalente al número de clases que se pretende clasificar. La salida conformada por una sola neurona es una señal formada por trenes de pulsos. Cada pulso es característico para una determinada configuración del conjunto de parámetros de la red, y a cada clase corresponde una frecuencia de pulsos; esta es la manera en que se realiza la clasificación. Para el reconocimiento de patrones con un número pequeño de clases, de una a tres, la arquitectura de la red neuronal puede constar de una sola neurona, lo cual no es posible con otros paradigmas. Para este estudio se hicieron uso de las bases de datos: iris, vino, vidrio y desordenes del hígado las cuales se obtuvieron del *Machine Learning repository*. Se realiza también experimentos de umbralado de imágenes, que consiste en la separación de fondo y forma (dos clases). Como ejemplo, se presenta en la Tabla 2.5 el promedio de clasificación de todos los experimentos de RP en su entrenamiento y en su validación.

Tabla 2.5. Aplicación de las Redes Neuronales Pulsantes en el Reconocimiento de Patrones y Análisis de Imágenes [Matadamas,2014]

Media de clasificación de los experimentos de reconocimiento de patrones usando funciones de transformación.

Base	Lineal		Polinomial		Producto		RBF		MLP	RNP[10]
	Ent.	Val.	Ent.	Val.	Ent.	Val.	Ent.	Val.	Val.	Val.
Planta de Iris	0.9853	0.9559	0.6366	0.6296	0.9799	0.9466	0.5652	0.5745	0.96	0.9308
Vino	0.9374	0.8633	0.4738	0.4621	0.9124	0.8932	0.4113	0.4044	0.9775	0.8319
Vidrio	0.6723	0.5847	0.3733	0.3467	0.6190	0.5275	0.3390	0.3293	0.6074	0.7411
Hígado	0.7592	0.7034	0.4691	0.4681	0.7319	0.6433	0.5778	0.5525	0.6279	0.6870

Classification and Segmentation of fMRI Spatio-Temporal Brain Data with a NeuCube Evolving Spiking Neural Network Model [Gholami, 2014]

En este trabajo se utilizan datos de imágenes de resonancia magnética funcional y el modelo de Red Neuronal Pulsante llamada *NeuCube* (SNNc) para analizar las áreas de actividad del cerebro mientras un sujeto humano lee oraciones afirmativas y negativas. La Red Neuronal Pulsante *NeuCube* (SNNc) representa un nuevo modelo para el aprendizaje, clasificación y comprensión cognitiva de los datos de Imágenes de

Resonancia Magnética Funcional (fMRI). Para el proceso de aprendizaje se utiliza un enfoque de RNP evolutiva (eSNN) y para el proceso de clasificación se utiliza un enfoque de RNP evolutiva dinámica (edSNN). El paradigma eSNN amplía los modelos de sistemas conexionistas evolutivos mediante el modelo neuronal de integración y disparo y el **aprendizaje de Orden de Rango (RO)**, el cual establece una prioridad de entradas en cada sinapsis, basada en el orden de la llegada del pulso para un patrón particular, sobre el supuesto de que la información más importante, está contenida en los primeros pulsos de llegada. Este fenómeno se observa en los sistemas biológicos. En la deSNN se crea una nueva neurona de salida para cada muestra de entrenamiento, y se conecta a todas las demás neuronas, cuyos pesos de conexión puestos en cero, pero que se modifican dinámicamente por nuevos trenes de pulsos de acuerdo con la regla de aprendizaje RO.

Los datos de fMRI proporcionan la localización espacial del cerebro en una celda tridimensional (un *voxel*), y la información temporal como la cuarta dimensión. Cada uno de estos *voxels* representa fluctuaciones en la intensidad BOLD (*Blood Oxygenation Level Dependent*) de miles de neuronas a lo largo del tiempo. Para la implementación del modelo computacional se utiliza un simulador de software escrito en MATLAB, que consta de tres módulos significativos: codificación y mapeo de datos fMRI, aprendizaje no supervisado y visualización SNNc parecida al cerebro, y aprendizaje supervisado y validación de resultados de clasificación (ver Figura 2.5).

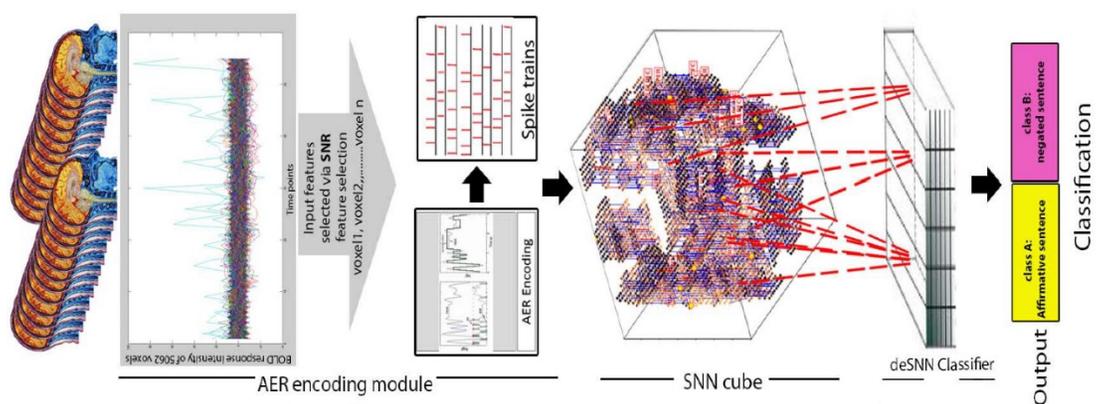


Figura 2.5. Diagrama a bloques de la arquitectura *NeuCube* con sus módulos principales para un caso de estudio sobre fMRI.

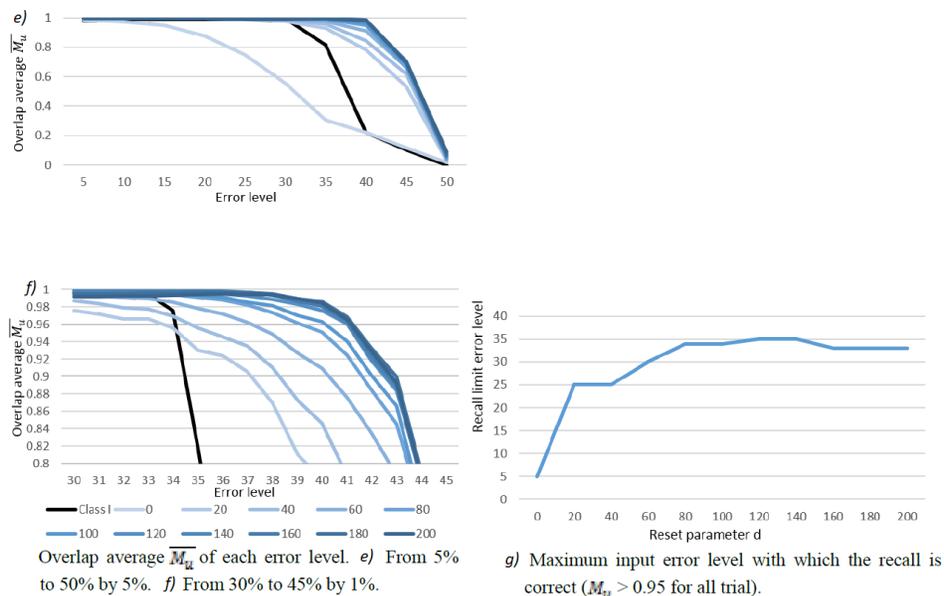
Los resultados experimentales muestran que los patrones de actividad cerebral del sujeto se comportaron de manera diferente en la oración afirmativa frente a la negativa. Con el modelo propuesto se logró una precisión de clasificación del 100% de los patrones de actividad de *voxels* correspondientes al estímulo de la oración negativa, y para la oración afirmativa fue del 80%. Con esto se concluye que los patrones de actividad cerebral de las oraciones negativas son más distinguibles que las oraciones afirmativas, notando además que en el hemisferio izquierdo se observa más actividad que el hemisferio derecho al leer un estímulo con oración negativas.

Associative Memory with Class I and II Izhikevich Model [Osawa, 2015]

Investiga la simulación de memoria asociativa utilizando el modelo de Izhikevich (2004) basada en el trabajo de [Li, 2012] que utiliza el modelo DSSN (*Digital Spiking Silicon Neuron*) compuesto por dos ecuaciones diferenciales que expresan el proceso de generación de pulsos sin restablecer las variables del sistema, a diferencia del modelo de Izhikevich que captura de manera cualitativa el proceso de decisión de pulsos, y representa el pulso al restablecer las variables del sistema, con lo cual reproduce una variedad de patrones de pulsos. Muestra que una red de neuronas de clase II completamente conectada tiene una capacidad de recuperación más alta que la de Neuronas de clase I, lo que significa que un patrón original almacenado se recupera de un patrón de entrada asociado con un error más alto. En este trabajo, Osawa configura una memoria asociativa similar utilizando el modelo de Izhikevich y evalúa la diferencia de rendimiento al centrarse en la forma de la curva de restablecimiento de fase PRC (*Phase Resetting Curve*).

La memoria asociativa está compuesta por redes conectadas completamente y genera un patrón almacenado similar a los datos de entrada. Se almacenan p patrones de N puntos que son ortogonales entre sí ($p = 4$, $N = 256$). Se utiliza el mismo modelo de sinapsis utilizada en [Li, 2012]. Se examina el rendimiento de la memoria asociativa compuesta por el modelo Izhikevich de Clase II, al variar el parámetro d . Los patrones de entrada se generan aplicando errores aleatorios a un patrón almacenado. Los experimentos muestran que, en la fase temprana del proceso de recuperación, las neuronas se activan de manera relativamente asíncrona, aumentando ésta, a medida que las neuronas continúan disparándose, hasta que las neuronas que corresponden a

puntos negros (blancos) se disparan de forma síncrona, aunque anti fásica. Se utiliza la superposición $M_u(t)$ para conocer el grado de emparejamiento del u -ésimo patrón. Se considera que la recuperación es correcta cuando la superposición es mayor que 0.95 para todas las pruebas. Realizan simulación para 100 patrones de entrada para cada nivel de error (con pasos del 1% y 5%), variando el parámetro de restablecimiento d , de cada neurona de 0 a 200 con un paso de 20. En la Figura 2.6 dada, incisos e), y f) se muestra el promedio de superposición para cada nivel de error. El inciso g), representa la tasa máxima de error de entrada desde la cual la red recordó el patrón correcto.



Associative Memory with Class I and II Izhikevich Model [Osawa, 2015]

Figura 2.6. Memoria asociativa con clases I y II del modelo de Izhikevich [Osawa, 2015]

Robustness of classification ability of spiking neural networks [Yang, 2015]

Realiza experimentación para probar la robustez de la capacidad de clasificación de una red neuronal pulsante que recibe entradas con ruido. Para este propósito se llevan a cabo una serie de experimentos numéricos sobre el problema XOR clásico y otras tres bases de datos de referencia: *Iris*, *Wisconsin breast cancer* y *StatLog landsat*. Para introducir el ruido, se utilizan los dos tipos de perturbaciones sinusoidal y gaussiana, las cuales se suman a la entrada original. La red neuronal pulsante utilizada es del tipo simple, de alimentación hacia adelante que consta de tres neuronas de entrada, cinco en la capa oculta y una en la salida. Para el entrenamiento de la red se utiliza el algoritmo de aprendizaje *SpikeProp*. En el problema de XOR, se utiliza el punto (1,1) para probar

la robustez de la red neuronal pulsante. Se varió la amplitud de la perturbación sinusoidal A , y r^* (el límite superior menor de todos los componentes al vector aleatorio r en la perturbación gaussiana) para controlar las amplitudes de perturbación. La red aprendió de manera confiable los patrones XOR con $\eta = 0.01$ (tasa de aprendizaje de la red). Los resultados obtenidos muestran que las tasas de clasificación correctas de la red no cayeron demasiado. Estos resultados indican que las redes neuronales pulsantes tienen fuertes habilidades anti-interferencias. Para las bases de datos de referencia, se utiliza una arquitectura de red neuronal similar a la de XOR. En la base de datos Iris, se miden cuatro características para cada muestra, que son, la longitud y el ancho de los sépalos y pétalos en centímetros, a las cuales se agregan las perturbaciones sinusoidal y gaussiana. La base de datos *Wisconsin breast cancer* está dividida en casos benignos y no benignos. Cada caso tiene nueve mediciones y a cada medición se le asigna un número entero entre uno y diez. Entre más grande el número, mayor probabilidad de casos no benignos. Los resultados para este caso se presentan en la Figura 2.7 a) y b).

a)				b)				b) cont.			
Epoches	A	ROS	RWS	Epoches	r^*	ROG	RWG	Epoches	r^*	ROG	RWG
1500	0.001	97.50	97.60	1000	0.1	95.75	96.06	1500	0.1	97.40	97.52
1500	0.01	97.34	97.20	1000	0.2	95.85	94.60	1500	0.2	97.13	96.59
1500	0.1	95.60	95.53	1000	0.3	94.75	94.86	1500	0.3	95.57	93.86
1500	0.2	95.50	93.80	1000	0.4	92.00	91.96	1500	0.4	96.03	95.45
1500	0.5	96.02	94.84	1000	0.5	91.57	91.17	1500	0.5	93.54	91.60
1500	0.8	93.56	91.68								

Wisconsin breast cancer a) sinusoidal and b) Gaussian perturbations

Figura 2.7. Serie de Tablas de resultados de la experimentación para probar la robustez de la capacidad de clasificación de una red neuronal pulsante que recibe entradas con ruido [Yang, 2015].

Se procedió de igual forma para las bases de datos *StatLog landsat dataset*. En todos los casos ROS significa “tasas de la clasificación correcta sin perturbaciones sinusoidales”, y RWS, “tasas de la clasificación correcta con perturbaciones sinusoidales”. De la misma manera ROG: Tasas de la clasificación correcta sin perturbaciones gaussianas, RWG: Tasas de la clasificación correcta con perturbaciones gaussianas.

Clasificación de patrones mediante el uso de una red neuronal pulsante [Hernández, 2016]

Ofrece una explicación elaborada de la clasificación de la función binaria XOR y de la base de datos *lonosphere*, utilizando una neurona de Izhikevich de tipo pulsante. Para la sesión de entrenamiento hace uso del algoritmo de evolución Diferencial (ED) basado en algoritmos genéticos. Comienza con una explicación del modelo matemático de la neurona pulsante de Izhikevich y de los parámetros involucrados, así como las ecuaciones matemáticas utilizadas para simular la entrada de corriente a la neurona. Posteriormente, explica cómo se realiza el proceso de mutación, cruza y selección del algoritmo de evolución diferencial que servirán para la inicialización de los pesos de las diferentes entradas a la neurona, que son dos en el caso de la función XOR, y treinta y cuatro para la base de datos *Inosphere*, que también tiene dos tipos de clases o categorías. Los resultados obtenidos para la clasificación de la función XOR, con sólo cuatro elementos de entrenamiento fue del 97.5% de patrones correctamente clasificados, y en el caso de la base de datos *lonosphere*, para la cual se utilizó el 20% de los datos como entrenamiento, se logró el 77.78% de datos correctamente clasificados del total de datos. La Tabla 2.6 muestra resultados de clasificación de la base de datos *Inosphere*.

Tabla 2.6. Clasificación de patrones mediante el uso de una red neuronal pulsante [Hernández, 2016]

Resultados de la clasificación de <i>lonosphere</i>	
Clase	Medias de disparos (Representante de clasificación)
Malos	14.9682
Buenos	37.02222

Deep into the Brain: Artificial Intelligence in Stroke Imaging [Lee, 2017]

Centra la atención en aplicaciones de técnicas de IA en la EVC, que se han estado desarrollando para mejorar la precisión del diagnóstico médico y la calidad del cuidado del paciente. Vaticina que, en un futuro cercano, probablemente estas técnicas jugarán un papel crucial en determinar métodos terapéuticos y en la predicción de pacientes con

algún tipo de trastorno EVC, y que favorecerán un concepto emergente llamado medicina de precisión que consistirá en el diagnóstico y terapia personalizados, gracias a la gran explosión de datos clínicos e imágenes alusivas. Considera que un tema atractivo de aplicación de estas técnicas es el estudio de imágenes cerebrales porque conllevan decisiones complejas dentro del ámbito de la EVC. Entre los paradigmas de IA que se analizan y describen de manera breve, están La Máquina de Soporte Vectorial (SVM), RNA: *Deep Learning*, Redes Neuronales Convolucionales (CNN), redes neuronales recurrentes (RNN), y algunas variantes de ellas (no menciona las PCNN). Todas enfocadas al estudio de imágenes relacionadas con trastornos de tipo EVC, para la realización de un diagnóstico automático preciso, y para la predicción efectiva de la presencia o no presencia del problema de EVC, expedida incluso por no neurólogos.

Tabla 2.7. Estudios con Aprendizaje Automático sobre imágenes de EVC [Lee, 2017]

Application	Setting	Imaging tool	Performance
Diagnosis			
Automatic lesion segmentation (ischemic stroke) ¹⁷	Subacute stroke (> 24 hours and < 2 weeks)	MRI	Inferior to human segmentation
Automatic lesion segmentation (ischemic stroke) ¹⁸	Chronic stroke	MRI (T1-weighted)	Comparable to manual segmentation
Automatic lesion segmentation (ischemic stroke) ¹⁹	Acute stroke	DWI	Comparable to manual segmentation
Determination of ASPECTS (e-ASPECTS) ^{20,21}	Acute stroke	CT	Non-inferior to human reading
Automatic diagnosis of MCA dot sign ²²	Acute stroke (< 24 hours)	CT	Sensitivity 97.5%
Estimation of CSF volume for infarct edema ²³	Acute stroke	CT	Better than conventional method
Automatic lesion segmentation (hemorrhagic stroke) ²⁵	Acute stroke	CT	Comparable to manual segmentation
Prognosis			
Symptomatic ICH after thrombolysis ²⁷	Acute stroke	CT	Improved the prognostic prediction
Improvement of visual function in PCA infarcts ²⁸	Subacute stroke (within 7 days)	MRI	Improved the prognostic prediction
Long-term mortality of AVM ³⁴	After endovascular treatment	CT, MRI	Accuracy of 97.5% to predict outcome
Impairment in multiple behavioral domains ³⁵	Subacute stroke (within 2 weeks)	MRI, fMRI	Enabled the prognostic prediction
Motor impairment ³⁶	Chronic stroke (≥ 3 months)	MRI, fMRI	Enabled the prognostic prediction

MRI, magnetic resonance imaging; DWI, diffusion weighted imaging; ASPECTS, Alberta Stroke Program Early Computed Tomography Score; CT, computed tomography; MCA, middle cerebral artery; CSF, cerebrospinal fluid; ICH, intracerebral hemorrhage; PCA, posterior cerebral artery; AVM, arteriovenous malformation; fMRI, functional magnetic resonance imaging.

Esto se basa en una segmentación automática efectiva de la lesión, lo cual consideran que es uno de los elementos más importantes, dado que la segmentación manual es tardada y lleva a resultados inconsistentes entre los evaluadores. Sin embargo, menciona que la segmentación automática en imágenes de resonancia magnética (MRI) no es una tarea fácil. Las formas y localizaciones de las lesiones varían por múltiples razones, de manera que delinear las lesiones de la EVC con estas técnicas no han mostrado superioridad sobre la segmentación manual humana, en la mayoría de los

casos, según muestran en Tabla 2.7 de este trabajo. Se muestra ejemplo gráfico del proceso de segmentación automatizada de lesiones de la EVC usando técnicas supervisadas de aprendizaje automático del mismo autor, en la Figura 2.8.

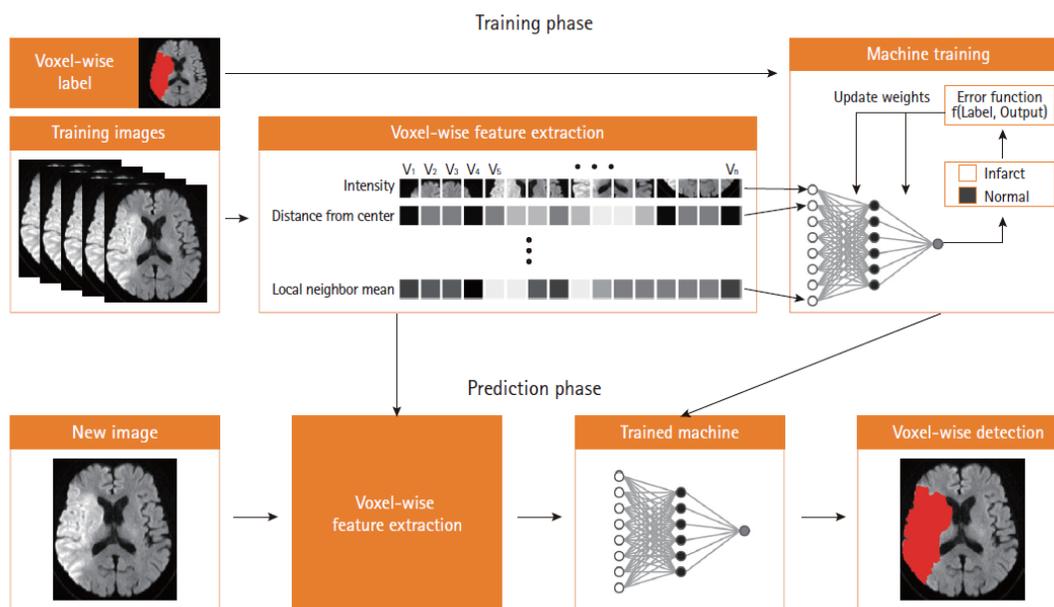


Figura 2.8. Flujo de trabajo esquemático del aprendizaje automático supervisado [Lee, 2017]

Automated Image Segmentation Using Improved PCNN Model Based on Cross-entropy [Ma, 2004]

En este documento se presenta un algoritmo diferente de segmentación de imágenes en iteraciones de ciclo automático, mejorando el mecanismo de segmentación de umbral del PCNN tradicional en combinación con la aplicación de la de entropía cruzada mínima. Primero define de manera vaga el concepto de segmentación, pero enfatiza su importancia en el análisis y procesamiento de imágenes, y hace notar que el punto clave de la segmentación, y el más difícil, es la búsqueda de un umbral adecuado para realizar la segmentación correcta, lo que hace que la imagen binaria no produzca una segmentación insuficiente ni una segmentación excesiva. También sin entrar en profundidad explica que es una Red Neuronal Pulso-Acoplada (PCNN) y sus orígenes, pero sí menciona su superioridad en el procesamiento de imágenes en aplicaciones como: el suavizado de imágenes, la segmentación y la extracción de bordes entre otras.

Indica que el modelo tradicional no puede mostrar la mejor estimación objetiva del resultado de la segmentación en el proceso de iteración y no puede controlar los tiempos de iteración, que también influyen en los resultados de la segmentación, por esta razón explica en que consiste su un modelo PCNN mejorado basado en el modelo tradicional, donde aplica el principio de entropía cruzada mínima como medida para controlar los tiempos de iteración de las redes, y luego presenta un método diferente de segmentación de imagen automatizado. Finalmente, el algoritmo se compara con el esquema de segmentación de PCNN aplicando el principio de entropía máxima de Shannon.

Concluye que, de acuerdo con los experimentos realizados, y los resultados obtenidos y mostrados, su nuevo modelo se comporta mejor que el modelo tradicional original, atribuyendo este resultado final a que el umbral del modelo PCNN tradicional cambia repetidamente, permitiendo que una gran cantidad de información procesada permanezca en el período de disparo o fase de la neurona, pero la imagen binaria de salida directa no contiene toda la información. Esto último explica la pérdida de detalles en la Figura 2.9c, respecto a la Figura 2.9b (ver Figura 2.9).

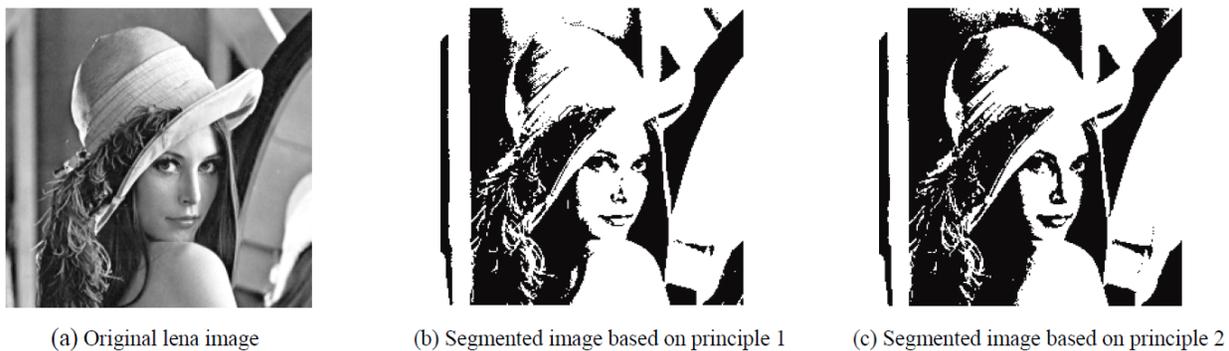


Figura 2.9. Comparación de segmentación de imágenes [Ma, 2004]

Applications of Pulse-Coupled Neural Networks [Ma, 2010]

Este libro analiza la PCNN en detalle y presenta algunas aplicaciones especiales y los resultados correspondientes basados en investigaciones propias de su equipo de investigadores. Primero proporciona información sobre las Redes Neuronales Pulso-Acopladas (PCNN) y algunas de sus variantes, incluyendo el Modelo Neuronal de Intersección Cortical (ICM), y el resto de los capítulos los emplea en la aplicación de

estos paradigmas en la solución de problemas de Filtrado, Segmentación, Codificación, Mejoramiento, Fusión, y Extracción de Características de imágenes, aparte de la aplicación de las PCNN en Optimización Combinatoria que aplica las PCNN en la solución de problemas en esa área como “El agente viajero”, “Encontrar la ruta más corta entre dos puntos” entre otras. Además, incluye un análisis de la implementación del algoritmo de las PCNN en el hardware FPGA. Este trabajo se fundamenta en gran parte en el capítulo III de este libro.

Supapixel Segmentation using Linear Spectral Clustering [Li&Chen, 2015]

Este artículo presenta los fundamentos de creación del algoritmo de segmentación de superpíxeles llamado *Linear Spectral Clustering* (LSC), el cual produce superpíxeles compactos y uniformes con bajos costos computacionales, constituyéndose como una alternativa más en la segmentación mediante superpíxeles, que es una técnica de preprocesamiento de imágenes cada vez más popular que se utiliza en muchas aplicaciones en Visión Artificial porque proporciona una representación de imagen concisa al agrupar píxeles en pequeños grupos perceptualmente significativos que se adhieren bien a los límites del objeto.

Comparan LSC con ocho algoritmos de segmentación de superpíxeles de última generación, incluidos SLIC, *SEEDS*, Ncuts, *Lattice*, ERS, *Turbopixel*, EneOpt1 y EneOpt0. Para los ocho algoritmos, las implementaciones se basan en código disponible públicamente, y la base de datos de segmentación Berkeley.

La adherencia a los límites de los superpíxeles generados por diferentes algoritmos se compara utilizando tres métricas de evaluación de uso común en la segmentación de imágenes: Error de *Subsegmentación* (UE), Recuperación de Límites (BR) y Precisión de Segmentación Alcanzable (ASA). UE evalúa la calidad de la segmentación de superpíxeles al penalizar los superpíxeles que se superponen con varios objetos. BR mide la fracción de los límites de *ground truth* recuperados correctamente por los límites de superpíxeles. ASA se define como la precisión de segmentación de objetos más alta que se puede lograr cuando se utilizan superpíxeles como unidades, tomando en cuenta la eficiencia computacional.

Según los resultados de sus experimentos cualitativos demuestran que LSC se desempeña mejor. Seleccionaron los cinco algoritmos (*SEEDS*, *Ncuts*, *SLIC*, *ERS* y *LSC*) que logran los valores de UE más bajos, y muestran ejemplos de la segmentación de superpíxeles utilizando estos algoritmos, donde se observa que *LSC* logra los resultados de segmentación más satisfactorios desde el punto de vista perceptivo para diferentes tipos de imágenes (ver Figura 2.10).

Concluyen que los resultados experimentales muestran que *LSC* generalmente supera a la mayoría de los algoritmos de vanguardia tanto cuantitativa como cualitativamente (ver Figura 2.10 y Tabla 2.8).

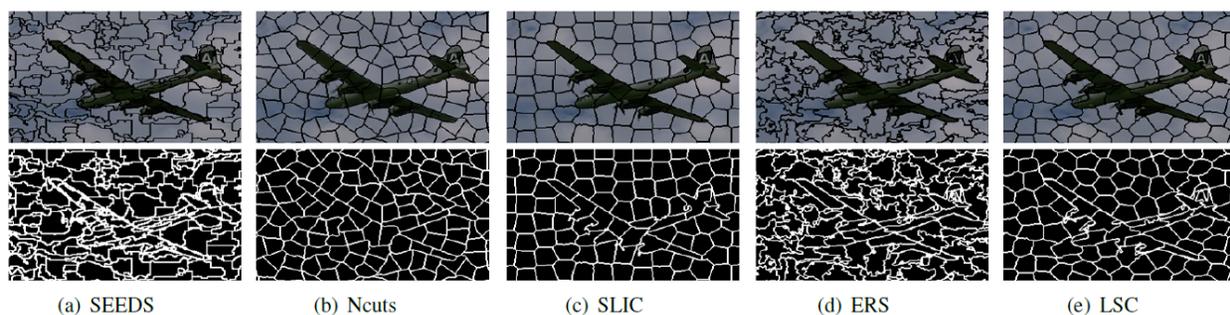


Figura 2.10. Comparación visual de segmentación de superpíxeles en $K = 400$

Tabla 2.8. Métricas de rendimiento de los algoritmos de segmentación de superpíxeles en $K = 400$

	EneOpt0	SEEDS	ERS	Lattices	Ncuts	SLIC	Turbo	LSC
Adherence to boundaries								
<i>Under segmentation error</i>	0.230	0.197	0.198	0.303	0.220	0.213	0.277	0.190
<i>Boundary recall</i>	0.765	0.918	0.920	0.811	0.789	0.837	0.739	0.926
<i>Achievable segmentation accuracy</i>	0.950	0.960	0.959	0.933	0.956	0.956	0.943	0.962
Segmentation speed								
<i>Computational complexity</i>	$\mathcal{O}(\frac{N^3}{K^2})$	$\mathcal{O}(N)$	$\mathcal{O}(N^2 \lg N)$	$\mathcal{O}(N^{\frac{3}{2}} \lg N)$	$\mathcal{O}(N^{\frac{2}{3}})$	$\mathcal{O}(N)$	$\mathcal{O}(N)$	$\mathcal{O}(N)$
<i>Average time per image</i>	8.22s	0.213s	2.88s	0.748s	273s	0.314s	20.2s	0.919s

Superpixels: An Evaluation of the State-of-the-Art [Stutz, 2017]

En este trabajo se presenta una evaluación integral de 28 algoritmos de superpíxeles de última generación centrada en un punto de referencia global para que comparación sea justa, para lo cual se pone énfasis en la optimización de parámetros y la conectividad. El estudio surge de la necesidad, dado que los algoritmos de superpíxeles se han convertido en herramientas estándar en la visión de bajo nivel, y con

el número de algoritmos en rápido crecimiento, así como las diferentes configuraciones experimentales, obstaculizan el desarrollo de un punto de referencia unificador. Debido a esto, los puntos de referencia apropiados son cruciales para su selección y comparación.

Utilizando métricas conocidas, como Recuperación de Límites (Rec), Error de Subsegmentación (UE) y Variación Explicada (EV), además de las métricas propuestas: Tasa de Fallos promedio (AMR), Error de Subsegmentación Promedio (AUE) y la "Variación Promedio Inexplicable" (AUV) realizan un resumen del rendimiento del algoritmo independientemente del número de superpíxeles generados, superando así una limitación importante de los puntos de referencia disponibles. Utilizan también: el mínimo / máximo, así como la desviación estándar de estas métricas para identificar algoritmos estables, es decir, algoritmos que proporcionan un rendimiento que aumenta monótonamente con respecto al número de superpíxeles generados

Toman en cuenta el tiempo de ejecución, la robustez frente al ruido, el desenfoque y las transformaciones afines, los detalles de implementación y los aspectos de la calidad visual, así como la independiencia de "*ground truth*"

Posteriormente realizan una clasificación general de algoritmos de superpíxeles. Para esto definen los superpíxeles como agrupaciones de píxeles perceptualmente similares como el color y otras propiedades de bajo nivel, que crean entidades visualmente significativas, y destacan su función en dos problemas inherentes al procesamiento de imágenes digitales: que los píxeles son el resultado de la discretización, y que la gran cantidad de píxeles en imágenes grandes impide que muchos algoritmos sean viables computacionalmente. Esto sustenta el hecho de el porque se han aplicado a muchos problemas importantes en la Visión Artificial, y otros dominios como la segmentación de imágenes médicas, conjuntos de datos, imágenes y video, en comparaciones de *supervoxels*, entre muchas más. Debido a este uso tan extendido, señalan que es común entre muchos autores la no distinción entre los algoritmos de superpíxeles y los algoritmos de sobresegmentación. Por esta razón adoptan la convención de que los algoritmos de superpíxeles ofrecen control sobre la cantidad de superpíxeles generados mientras los algoritmos de sobresegmentación no.

Según su estudio, muchos autores están de acuerdo con los siguientes requisitos para los superpíxeles: **Dividir:** Los superpíxeles deben estar separados y asignar una etiqueta a cada píxel. **Conectividad:** Se espera que los superpíxeles representen conjuntos de píxeles conectados. **Adherencia a los límites:** Los superpíxeles deben preservar los límites de la imagen. **Compactancia, Regularidad y Suavidad:** En ausencia de límites de imagen, los superpíxeles deben ser compactos, colocados regularmente y exhibir límites suaves. **Eficiencia:** Los superpíxeles deben generarse de manera eficiente. **Número controlable de superpíxeles:** El número de superpíxeles generados debe poder controlarse.

Encontraron que se pueden generar hasta aproximadamente 20000 superpíxeles sin pérdida de información apreciable.

Tabla 2.9. AMR y AUE promedio, rangos promedio y distribución de rango para cada algoritmo evaluado. Para calcular los rangos promedio, los algoritmos se clasificaron de acuerdo con AMR + AUE (donde el AMR + AUE más bajo corresponde al mejor rango, es decir, 1) en cada conjunto de datos por separado. Para todos los algoritmos (filas), la distribución de rango (columnas 1 a 28) ilustra la frecuencia con la que se alcanzó un rango particular en todos los conjuntos de datos considerados. No se pudieron evaluar RW, NC y SEAW, DASP, VCCS con alguna de las bases de datos utilizadas [Stutz, 2017].

AMR	AUE		Rank	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
2.05	6.07	ETPS	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1.57	7.98	SEEDS	3.8	0	2	1	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3.38	6.28	ERS	3.8	0	1	1	2	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4.16	6.29	CRS	4.8	0	0	2	1	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4.18	6.77	EAMS	5.4	0	1	1	0	0	1	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4.55	6.34	ERGC	5.8	0	0	0	0	2	2	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4.91	6.50	SLIC	6.2	0	0	0	0	2	0	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5.40	7.24	LSC	9.2	0	0	0	1	0	1	0	0	2	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
5.49	7.02	preSLIC	9.2	0	0	0	0	0	0	2	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6.60	6.41	CCS	10.6	0	0	0	0	0	0	2	0	1	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6.49	7.19	CW	11	0	0	0	0	0	0	0	0	2	2	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8.24	7.83	DASP	12	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6.51	7.44	W	12.8	0	0	0	0	0	0	0	0	0	2	1	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
7.44	6.97	WP	13.4	0	0	0	0	0	0	0	0	0	0	0	1	2	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0
7.85	7.58	POISE	13.8	0	1	0	0	0	0	0	0	0	0	0	1	0	1	1	0	0	0	0	0	0	0	1	0	0	0	0	0
8.13	6.90	NC	15.25	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0
7.66	7.43	MSS	15.8	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	2	1	0	0	0	0	0	0	0	0	0	0	0
8.90	7.67	VC	17.8	0	0	0	0	0	0	0	0	0	0	0	0	1	2	0	0	1	0	0	0	1	0	0	0	0	0	0	
8.31	7.85	PB	18.4	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	1	1	1	0	0	0	0	0	0	0	
8.53	8.15	FH	19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	3	0	1	0	0	0	0	0	0	0	
8.35	7.32	RW	19	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	1	0	0	1	0	0	1	0	0	0	0	
11.45	6.70	CIS	20.8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	2	0	0	0	1	0	0	0	0	
11.45	7.19	TPS	21	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	1	1	0	1	0	0	0	
11.05	7.93	TP	21.6	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	1	1	0	1	0	0	0	
14.22	13.54	VCCS	23	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	
11.97	8.36	SEAW	24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	2	0	1	0	0	0	
15.72	10.75	QS	24.8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	2	0	1	0	0	
24.64	14.91	PF	26.2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	3	0	1	

La Tabla 2.9 resume la clasificación realizada. Como resultado, recomiendan seis algoritmos que cubren muchos escenarios de aplicación, estos algoritmos son: ETPS (*Extended Topology Preserving Segmentation*), SEEDS (*Superpixels Extracted via*

Energy-Driven Sampling), ERS (*Entropy Rate Superpixels*), CRS (*Contour Relaxed Superpixels*), ERGC (*Eikonal Region Growing Clustering*) y SLIC (*Simple Linear Iterative Clustering*), que muestran un rendimiento superior con respecto a la Recuperación de Límite (*Rec*), el Error de *Subsegmentación* (UE) y Variación Explicada (EV), y pueden considerarse estables. Se observa que *Linear Spectral Clustering* (LSC) y *Watershed* (W), ocupan los lugares ocho y trece respectivamente.

An Overview of Watershed Algorithm Implementations in Open Source Libraries [Kornilov, 2018]

En este artículo se describen los resultados de la evaluación comparativa de seis implementaciones del algoritmo *Watershed* controladas por marcadores de código abierto para la segmentación de imágenes 2D y 3D. Estas implementaciones tienen un rendimiento significativamente diferente, pero las soluciones consideradas se basan en el mismo algoritmo por inundación que tiene una complejidad computacional $O(n)$.

Tabla 2.10. Tiempo de procesamiento de imágenes [Kornilov, 2018]

A) Average processing time with WL (ns/element).								B) Average processing time without WL (ns/element).							
Library	Image							Library	Image						
	2D				3D				2D				3D		
	Board	Cells	Coins	Fruits	Maze	Avg.	Balls		Board	Cells	Coins	Fruits	Maze	Avg.	Balls
ITK	306	380	328	332	292	328	1053	ITK	201	246	210	214	193	213	630
Mahotas	167	249	195	202	163	195	290	Mahotas	165	237	192	194	161	190	298
Mamba	64	141	94	94	57	90	207	Mamba	49	115	75	75	40	71	160
Skimage	1225	2740	1251	1326	1439	1596	8392	Skimage	271	466	305	312	252	321	499
SMIL	112	182	127	132	140	139	250	SMIL	102	163	140	141	116	132	245
OpenCV	36	50	34	38	31	38	—								

Este algoritmo se basa en la representación de una imagen cuyos valores de intensidad de la escala de grises, forman las diversas alturas de un relieve topográfico, compuesto de valles bajos (mínimos), cordilleras de gran altitud (líneas de *watershed*), declives (cuencas de captación), y mesetas (área con elementos de la misma altura).

Las Implementaciones librerías de software empleados son: ITK, *OpenCV*, *Mahotas*, *Mamba*, *Skimage* y SMIL, las cuales se pueden clasificar por la propiedad de *actividad de desarrollo y actualización*, y por la relación entre su *vida útil*, y el *número de*

sus versiones. Utilizaron el lenguaje *Python* para medir los recursos computacionales de las implementaciones. Los resultados se muestran en la Tabla 2.10.

An Overview of Image Segmentation Based on Pulse-Coupled Neural Network [Lian, 2019]

Este artículo presenta información muy importante porque ofrece un panorama bastante completo de lo más relevante sobre segmentación de las Redes Neuronales Pulso-Acopladas (PCNN). Comienza contextualizando de manera somera el concepto de segmentación y su importancia en procesamiento de imágenes, porque una vez que se tiene una imagen segmentada mediante un algoritmo, el siguiente paso puede ser la extracción de características, la identificación y/o clasificación de objetos.

Menciona el origen (modelo de Eckhorn), digitalización (PCNN de Johnson basado en modelo de Eckhorn) y los modelos clásicos modificados de Ranganath y Kinser. Explica la estructura básica general y sus partes principales, *Feeding*, *Linking*, estado interno, estímulo, efectos de neuronas vecinas, umbral y factores de decaimiento, etc., ecuaciones correspondientes y esquema general. Expone los modelos clásicos modificados para segmentación de imágenes: ICM, RG-PCNN, SCM y SPCNN, sus ecuaciones, y partes y parámetros principales.

Describe las propiedades dinámicas de cada parte del modelo básico de manera general, procurando que abarque los modelos modificados. Menciona la técnica de segmentación utilizando PCNN y la máxima entropía, la matriz de tiempos que registra la secuencia de disparo neuronal, todo con sus ecuaciones y parámetros principales. Expone la configuración de parámetros de manera general: tipos de estímulos, factores de decaimiento exponenciales, amplitudes de entrada del F, L y umbral. Los tipos de la fuerza del *Linking* (β), los tipos de matrices sinápticas que emulan el efecto de las neuronas vecinas. Explica el modelo complejo PCNN y sus divisiones en modelo heterogéneo y multicanal, para segmentaciones en color (ver Figura 2.11).

Finalmente explica las aplicaciones de segmentaciones de imágenes naturales, e imágenes médicas de diferentes partes del cuerpo, para terminar con una lista muy larga de diversas aplicaciones, todo referenciado. Concluye que es probable que, en el futuro, la PCNN fusionará la segmentación semántica y el aprendizaje profundo y

probablemente generará nuevos marcos de segmentación de imágenes y permitirá un avance más rápido que los algoritmos de última generación.

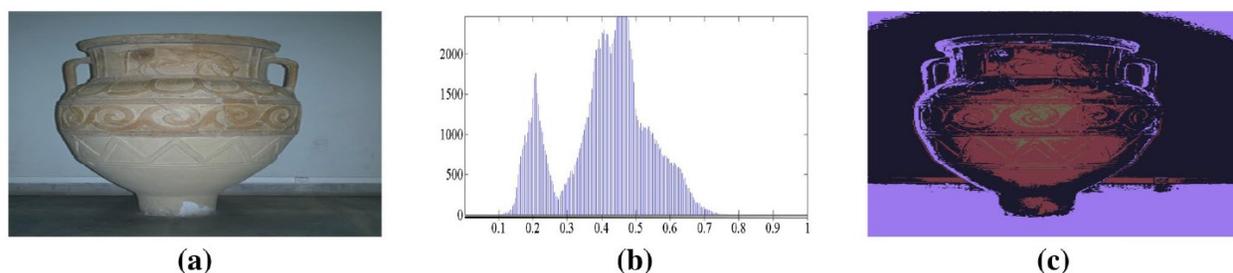


Figura 2.11. Ejemplo de la segmentación PCNN heterogénea: a) imagen original; b) Histograma de la imagen original; c) Resultados de la segmentación de PCNN heterogénea.

2.3. Discusión

En la Tabla 2.11 se muestra, un análisis de los trabajos representativos que forman parte del total de trabajos analizados, los cuáles muestran una relación ya sea directa o indirecta en la realización de este documento. Sin excepción, todos estos trabajos contribuyeron de alguna manera, con ideas, contenido, información o bibliografía para la elaboración del presente documento.

Tabla 2.11. Relación de los trabajos presentados dados en forma sintética

Trabajo Analizado	Trabajo Interno/Externo al CENIDET	Observación
Implementación y Evaluación de Redes Neuronales Artificiales tipo "Pulse-Coupled Neural Networks" (PCNN) Aplicadas a Visión Artificial [Cárdenas, 2015].	Antecedente Institucional	Este trabajo de tesis es pionero en la aplicación de PCNN dentro de la Institución CENIDET, y es el que más se acerca al contenido del presente trabajo dado que también utiliza el concepto de entropía y la segmentación de bordes y regiones utilizando las variantes de la PCNN, ICM. Sin embargo, utiliza sólo dos imágenes para su estudio, y la aplicación de otras métricas. En este trabajo se va más lejos, con el análisis de 150 imágenes/estudio y la extensión del análisis de éstas con diferentes algoritmos que incluyen segmentación con superpíxeles.

Tabla 2.11. Relación de los trabajos presentados dados en forma sintética (continuación)

Trabajo Analizado	Trabajo Interno/Externo al CENIDET	Observación
Extracción de Características de Imágenes Digitales mediante una Red Neuronal Artificial Pulsante [Zárate, 2015] .	Antecedente Institucional	Este trabajo de tesis también utiliza la PCNN ICM, pero aplicado al estudio de "firmas" de una imagen. Contribuye en la comprensión y aplicación del paradigma ICM.
Detección de Ruido Impulsivo o Gaussiano en Imágenes Monocromáticas Mediante Redes Neuronales Artificiales Pulso-Acopladas [Ortiz, 2017] .	Antecedente Institucional	En este un trabajo de tesis Institucional también utiliza variantes de la PCNN ICM, pero aplicadas para la detección y filtrado de ruido impulsivo y gaussiano en imágenes digitales. Contribuye en la comprensión y aplicación del paradigma ICM.
Aplicación del Descenso de Gradiente para el Aprendizaje de Neuronas Pulsantes de Izhikevich. [Hernández, 2017] .	Antecedente Institucional	Este trabajo de tesis Institucional es importante porque es pionero en el uso de RNP en la clasificación de imágenes digitales dentro del CENIDET. Se relaciona de manera indirecta, dado que Básicamente experimenta con la red neuronal de Izhikevich de tercera generación, como clasificador, así como experimentación con diferentes algoritmos de aprendizaje. Contribuye en la comprensión y aplicación de RNP.
Segmentación no Paramétrica de Tejidos Cerebrales Mediante una Arquitectura Paralela de Redes Neuronales Convolucionales [Morales, 2018] .	Antecedente Institucional	Este es un trabajo de tesis Institucional que se relaciona de manera directa, dado que aborda el estudio de la segmentación de imágenes digitales del cerebro humano, aunque utiliza frameworks de aplicación de Redes Neuronales Artificiales Convolucionales de la primera generación, que consumen mucho tiempo y recursos computacionales por el empleo de un gran número de imágenes de entrenamiento y validación.
Mejoramiento de la Luminosidad de Imágenes Digitales del Cerebro Humano mediante Redes Neuronales Pulso-Acopladas [Aguilar, 2019] .	Antecedente Institucional	En este trabajo de tesis Institucional, se proponen y emplean dos variantes de la PCNN ICM para mejorar la luminosidad en imágenes digitales del cerebro humano, y se realiza una comparativa con algoritmos tradicionales. Contribuye en la comprensión y aplicación del paradigma ICM.
<i>Automated Image Segmentation Using Improved PCNN Model Based on Cross-entropy</i> [Ma, 2004] .	Trabajo externo	Este artículo se relaciona de manera directa con el presente trabajo dado analiza el uso de la entropía cruzada en la segmentación de imágenes médicas, mediante el Modelo Neuronal de Intersección Cortical ICM. Es un artículo que complementa el trabajo del mismo autor en su libro: "Applications of PCNN", parte fundamental también para este trabajo.

Tabla 2.11. Relación de los trabajos presentados dados en forma sintética (continuación)

Trabajo Analizado	Trabajo Interno/Externo al CENIDET	Observación
<i>Image Processing Using Pulse-Coupled Neural Networks</i> [Lindblad, 2005].	Trabajo externo.	Este es un libro pionero que revisa la teoría, aplicaciones y algoritmos de la Red Neuronal Pulso-Acoplada (PCNN) y la variante, el Modelo Neuronal de Intersección Cortical (ICM), Su contenido se relaciona de manera directa con el presente trabajo, dado que se fundamenta en gran parte en los capítulos 1, 2 y 3.
<i>Applications of Pulse-Coupled Neural Networks</i> [Ma, 2010].	Trabajo Externo	Este es un libro muy completo sobre aplicaciones de las PCNN que todo investigador de ese campo debe conocer. El libro se relaciona de manera directa con el presente trabajo, dado que se fundamenta en gran parte en los capítulos I y III, que investiga la Segmentación de Imágenes mediante las PCNN y la entropía.
<i>Which Model to Use for Cortical Spiking Neurons?</i> [Izhikevich, 2004].	Trabajo externo	En este artículo se analiza la plausibilidad biológica y la eficiencia computacional de algunos de los modelos de neuronas pulsantes más útiles, y se realiza una comparación y contraste de varios modelos de neuronas pulsantes, lo cual contribuye de manera indirecta en la comprensión y ubicación computacional de las RNP.
<i>Early Diagnosis of Ischemia Stroke using Neural Network</i> [Thakur, 2009].	Trabajo externo	Con la lectura de este artículo se dio inicio al estudio de la segmentación y clasificación de imágenes en el presente trabajo, motivo por el cual, aunque utiliza RNA de la primera generación, se considera muy importante su aportación.
<i>Pulse-Coupled Neural Networks applied to Human Brain Image Processing</i> [Cárdenas, 2014].	Se considera en ambas categorías.	Este artículo es una extensión del trabajo de tesis del mismo autor, pero es importante porque el mismo problema se aborda utilizando diferente perspectiva.
Aplicación de las Redes Neuronales Pulsantes en el Reconocimiento de Patrones y Análisis de Imágenes [Matadamas, 2014].	Trabajo externo	Este es un trabajo de tesis externo que se relaciona de manera indirecta, dado que aborda otro paradigma de Redes Neuronales Pulsantes (RNP) aplicadas a la clasificación de imágenes digitales, estudio muy relacionado con la segmentación de imágenes, que, además, en su momento contribuyó en la comprensión de las RNP.
<i>Classification and Segmentation of fMRI Spatio-Temporal Brain Data with a NeuCube Evolving Spiking Neural Network Model</i> [Gholami, 2014].	Trabajo externo	Este es un artículo que se relaciona de manera directa, dado que aborda el estudio de la segmentación y clasificación de imágenes digitales del cerebro humano que utiliza un modelo radical de RNP en tres dimensiones y con un gran número de neuronas que incrementan de forma automática tanto el número de ellas como sus conexiones. Es un trabajo muy avanzado que arroja mucha luz sobre el estado del arte en el empleo de RNP.
<i>Associative Memory with Class I and II Izhikevich Model</i> [Osawa, 2015].	Trabajo externo	Este es un artículo que se relaciona de manera indirecta, dado que Investiga la simulación de memoria asociativa utilizando el modelo de red neuronal pulsante de Izhikevich que recibe entradas con ruido. En su momento contribuyó en la comprensión de las RNP, y clasificación de imágenes.

Tabla 2.11. Relación de los trabajos presentados dados en forma sintética (continuación)

Trabajo Analizado	Trabajo Interno/Externo al CENIDET	Observación
<i>Robustness of classification ability of spiking neural networks</i> [Yang, 2015].	Trabajo externo	Este es un artículo que se relaciona de manera indirecta, dado que realiza experimentación para probar la robustez de la capacidad de clasificación de una red neuronal pulsante que recibe entradas con ruido. En su momento contribuyó en la comprensión de las RNP, y clasificación de imágenes.
Clasificación de patrones mediante el uso de una red neuronal pulsante [Hernández, 2016].	Se considera en ambas categorías.	Este artículo es una extensión del trabajo de tesis del mismo autor, pero es importante porque igualmente, el mismo problema se aborda utilizando diferente perspectiva.
<i>Deep into the Brain: Artificial Intelligence in Stroke Imaging</i> [Lee, 2017].	Trabajo externo	Este artículo también es considerado muy importante porque fue pilar en la iniciación del estudio de la segmentación y clasificación de imágenes médicas, el cual vaticina que, en un futuro cercano, probablemente las técnicas de IA jugarán un papel crucial que favorecerán un concepto emergente llamado medicina de precisión que consistirá en el diagnóstico y terapia personalizados. Considera que un tema atractivo de aplicación de estas técnicas es el estudio de imágenes cerebrales porque conllevan decisiones complejas dentro del ámbito médico.
<i>Segmentación de superpíxeles mediante agrupación espectral lineal</i> [Li&Chen, 2015].	Trabajo externo	Este artículo también es muy importante porque se relaciona de manera directa, dado que presenta los fundamentos de creación del algoritmo de segmentación de superpíxeles llamado <i>Linear Spectral Clustering</i> (LSC), que es una técnica de preprocesamiento de imágenes cada vez más popular que se utiliza en el presente trabajo.
<i>Superpixels: An Evaluation of the State-of-the-Art</i> [Stutz, 2017].	Trabajo externo	Este artículo también es muy importante porque se relaciona de manera directa, dado que realiza una investigación del estado del arte en algoritmos de segmentación de superpíxeles. Contribuye con información importante al respecto.
<i>An Overview of Watershed Algorithm Implementations in Open Source Libraries</i> [Kornilov, 2018].	Trabajo externo	Este artículo también es muy importante porque se relaciona de manera directa, dado que se describen los resultados de la evaluación comparativa de seis implementaciones del algoritmo <i>Watershed</i> (que se emplea en este trabajo), controladas por marcadores de código abierto para la segmentación de imágenes 2D y 3D. Contribuye con información importante al respecto.
<i>An Overview of Image Segmentation Based on Pulse-Coupled Neural Network</i> [Lian, 2019].	Trabajo externo	Este artículo también es muy importante porque se relaciona de manera directa, dado que ofrece un panorama bastante completo de lo más relevante sobre segmentación mediante las Redes Neuronales Pulso-Acopladas (PCNN), incluyendo el paradigma ICM.

Capítulo 3 Marco Teórico

En este capítulo se presentan los fundamentos teóricos que subyacen en la realización de este proyecto de tesis, según lo especifica el capítulo 1, en su apartado 1.10: “Metodología de solución”, que, dentro de la Fase I, dice: “Comprende el Estudio de los fundamentos biológicos y computacionales de las redes RNA tradicionales y Pulsantes, sobre todo, investigación del estado del arte de estas últimas ...”. Este compromiso se vio reforzado con la sugerencia encontrada en varios artículos analizados, según la cual, la comprensión de las Redes Neuronales Artificiales descansa en una comprensión holística de las Redes Neuronales Biológicas [Hassabis, 2017]. Es por esta razón que la extensión de este capítulo tiene como propósito presentar sólo parte del estudio realizado, primeramente, de las Redes Neuronales Biológicas (que implican el estudio del *Sistema Nervioso* como un todo), para continuar con las Redes Neuronales Artificiales de 1ra, 2da y 3ra generación. Análisis que forma el sustento principal de todo estudio posterior dentro de este documento de tesis.

3.1. Cerebro e Inteligencia Artificial

Constituido con sus más de cien mil millones de neuronas organizadas en circuitos neuronales específicos, que forman la maquinaria que controla nuestras acciones y la percepción del mundo que nos rodea, el cerebro humano, un órgano que en promedio pesa 1.3 Kg, es considerado el órgano más complejo del universo, porque es capaz de concebir el infinito, descubrir nuevos conocimientos, y ser responsable de cada pensamiento, sentimiento, y acciones que caracterizan a cada ser humano.

Envuelta en un halo de misterio que rodea a la manera de cómo funciona el cerebro, y aunado a la curiosidad científica, se han hecho grandes esfuerzos en muchas áreas de las ciencias: *Las Neurociencias*, por llegar a dilucidar los procesos cerebrales que subyacen tanto en los actos más “simples” como caminar y comer, como también en comportamientos cognitivos complejos considerados esencialmente humanos, como pensar, hablar y crear obras de arte. Por esta razón, no es sorpresa que la fascinación y

admiración del ser humano por el cerebro, y que data de miles de años, sea éste fuente de inspiración para la Inteligencia Artificial (IA), otro campo del conocimiento que, por medio de sus múltiples paradigmas, intenta imitar la inteligencia humana en sus diferentes facetas, y que, a lo largo del tiempo ha tenido una historia entrelazada con el campo de las neurociencias, de tal manera que en las últimas décadas estos dos campos se han retroalimentando mutuamente, de tal forma, que el argumento de la creación de máquinas inteligentes en el campo de la IA, se debe fundamentar en una mejor comprensión del cerebro humano y otros animales [Hassabis, 2017] [Shapshak, 2018] [Kandel, 2013].

3.2. Inicios de la Neurociencia

Desde finales del siglo XX se ha venido convirtiendo en realidad el antiguo sueño de la humanidad de atisbar dentro del cerebro y observar la actividad de diferentes regiones del mismo, justo en el momento en que una persona realiza diversas funciones mentales superiores como la observación de una imagen visual, la percepción de sus colores y formas, el iniciar una acción de movimiento involuntaria, etc. Todo gracias a las técnicas modernas en Imagenología, que permiten obtener y analizar imágenes del cerebro, como, por ejemplo, la Tomografía por Emisión de Positrones (PET), y la Resonancia Magnética Nuclear (NMR), que, junto con el nacimiento de la Biología Molecular, finalmente es posible entender a escala molecular, los procesos por los cuales el ser humano percibe, actúa, aprende, recuerda, y como estos procesos se relacionan con regiones específicas del cerebro.

Desde hace más de dos mil años, Hipócrates proponía que el estudio adecuado de la mente comienza con el estudio del cerebro, y Sócrates y Platón especulaban sobre los procesos mentales. En el siglo XVII, la visión dualista de Descartes distinguía entre cuerpo y mente como dos entidades separadas, donde las funciones mentales superiores propiamente humanas no residían en ninguna parte del cuerpo, sino en el “alma”, lo cual fue refutado por Spinoza en su visión unificadora de mente y cuerpo.

En el siglo XVIII prevalecieron dos corrientes de pensamiento sobre la mente, en la cual los “empiristas” sostenían que el cerebro era una “tabula rasa” que hay que llenar con experiencia sensorial, mientras que los “idealistas” encabezados por Immanuel Kant,

creían que la percepción del mundo es producto particular de nuestra estructura cerebral. Por su parte Darwin, a mediados del siglo XIX postulaba que el cerebro era el “asiento de todo comportamiento”, y que, para entenderlo, se podían utilizar los animales como modelos de comportamiento, lo cual sentó las bases de los estudios modernos del cerebro, y dio también inicio a la psicología experimental. Pero el estudio en Fisiología del *Sistema Nervioso* inició en el siglo XVIII con el descubrimiento de las propiedades eléctricas en células de tejidos vivos, por Galvani, aunque Galeno, médico griego del siglo II, ya proponía que “los nervios transportan líquido secretado por el cerebro y la médula espinal a la periferia del cuerpo”. Posteriormente, a mediados del siglo XIX, un equipo de fisiólogos comandados por Hermann von Helmholtz lograron medir la señal eléctrica a lo largo de fibras nerviosas. También, mediante estudios farmacológicos, tres científicos europeos Bernard, Ehrlich y Langley descubrieron que las células nerviosas pueden comunicarse por medios químicos.

El estudio del sistema nervioso nació como ciencia con el trabajo monumental de Santiago Ramon y Cajal, apoyado en el método de tinción de las células nerviosas mediante sales de plata, desarrollado por Camillo Golgi, en el que distinguió células discretas en lugar de un entramado reticular nervioso sin aparente continuidad, ni solución, como se creía hasta entonces. Acuñó el nombre de *neurona* para estos componentes discretos que observaban una estructura tripartita compuesta por “procesos” o ramificación arbórea: “las dendritas” y un “proceso” o protuberancia de forma alargada, tubular cónica y redondeada: “el axón”, unidos en extremos opuestos a un cuerpo irregular o “soma”. Estas observaciones culminaron en su “doctrina de la neurona” como una teoría sobre la manera en que se organizan las redes neuronales biológicas, sustentada en los principios básicos:

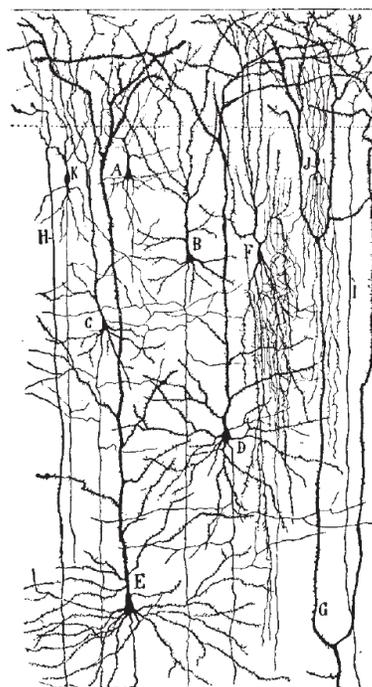


Figura 3.1. Uno de los dibujos de la circuitería del cerebro de Ramón y Cajal [Bear, 2016] [Gerstner-Kistler, 2014]

1) Las neuronas individuales son los componentes básicos y elementos de señalización del *Sistema Nervioso* (Figura 3.1). La neurona recibe información proveniente de otras neuronas por medio de las dendritas, y responde enviando información o no, a través del axón a otras neuronas unidas por medio de espacios interneuronales o “sinapsis”. 2) Las señales eléctricas dentro de una neurona fluyen sólo en una dirección, de las dendritas al cuerpo celular y de ahí, la señal eléctrica se propaga a lo largo de toda la longitud del axón hasta las terminales sinápticas con otras neuronas, lo que se llama: “Principio de polarización dinámica”. 3) Las neuronas forman conexiones sinápticas con otras neuronas en formas bien definidas o específicas llamadas “circuitos neurales”, cada uno de los cuales corresponde a un comportamiento específico (como por ejemplo la audición o la visión), a lo que se llamó: “Principio de especificidad de conexión neuronal”. Los últimos dos principios forman la base para el moderno enfoque conexionista del cerebro o neuro-computación, paradigma de la Inteligencia Artificial que modela cómo funciona el cerebro [Hassabis, 2017] [Shapshak, 2018] [Kandel, 2001] [Kandel, 2007] [Kandel, 2013] [Bear, 2016] [Gerstner-Kistler, 2014]

3.3. El Sistema Nervioso

La mayoría de los organismos vivos del reino animal, para transferir información de una parte del organismo a otra, y de esta manera responder de manera eficiente a los estímulos externos o internos (del mismo animal), ejecutando una serie de acciones para asegurar su supervivencia, desarrollaron un conjunto de células especializadas: las células nerviosa o neuronas, organizadas en una estructura que exhibe *simetría bilateral* que conforma el *Sistema Nervioso*.

De entre las especies que poseen un sistema nervioso, el más evolucionado es el de los mamíferos porque son los únicos que poseen una estructura llamada *neocórtex* o *neocorteza* que de hecho es la parte más evolucionada de la *corteza cerebral*, encargada de las funciones cerebrales superiores (capacidades cognitivas), que, en proporción, es más grande en el ser humano. El sistema nervioso entre mamíferos comparte muchas características comunes.

Atendiendo a su anatomía, el sistema nervioso humano se subdivide en *Sistema Nervioso Central* (SNC) y *Sistema Nervioso Periférico* (SNP) (Figura 3.2A), y éste a su

vez se subdivide en SNP *Somático* y SNP *Autónomo* o *Visceral*. El sistema nervioso central comprende el cerebro y la *médula espinal* (Figuras 3.2A y 3.3A). El cerebro está encapsulado dentro del cráneo y la médula espinal está en el centro de la columna vertebral. El SNP somático consiste en los nervios craneales y espinales que emergen del cerebro y de la médula espinal respectivamente. A través de estos nervios fluye información desde los órganos sensoriales y receptores del organismo, como la piel, los ojos, los músculos de movimiento voluntario, señales de tacto, presión y dolor, etc., hacia el sistema nervioso central, lo que constituye la información *aferente*, *sensorial* o *receptiva*, y desde el sistema nervioso central hacia los músculos y glándulas del cuerpo, o información *eferente* o *motora*, como, por ejemplo, la contracción de músculos voluntarios.

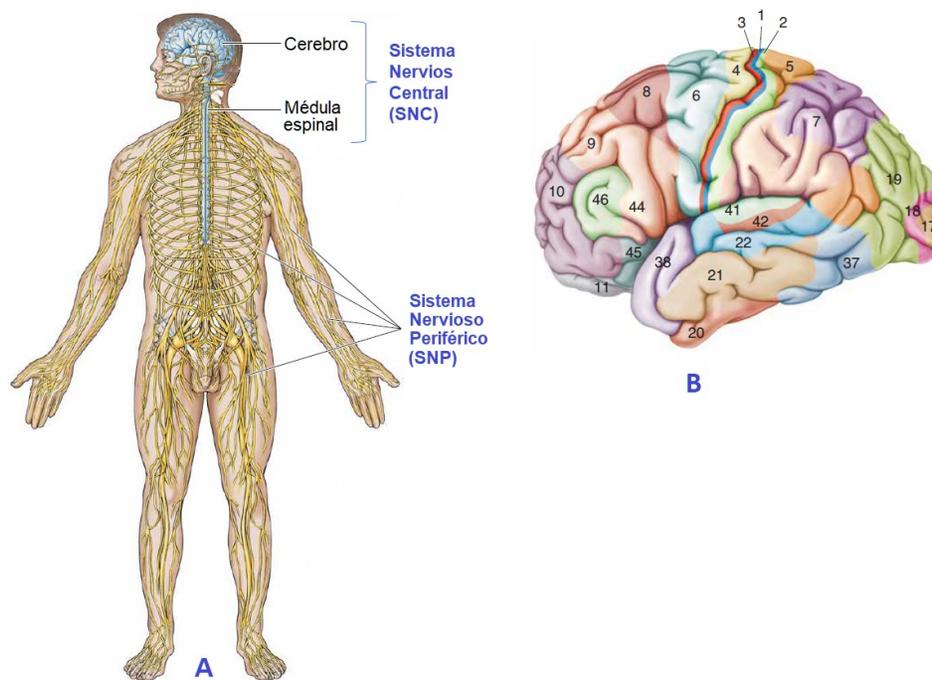


Figura 3.2. **A)** Sistema Nervioso formado por el SNC y el SNP. **B)** Mapa de Brodmann de la citoarquitectura de la corteza cerebral humana. Ejemplo, áreas: 3, 1 y 2) corteza somatosensorial primaria, 4) Corteza motora primaria [Bear, 2016]

El SNP Autónomo inerva los órganos internos, vasos sanguíneos y glándulas. Regula la presión y cantidad de oxígeno en la sangre y arterias. Comanda las contracciones y relajaciones de *músculos lisos* como las paredes intestinales y vasos sanguíneos, así como la tasa de movimientos de contracción del corazón y las funciones

secretoras de glándulas etc. [Bear, 2016] [Arbib, 2007] [Gerstner-Kistler, 2014] [Dayan-Abbott, 2002].

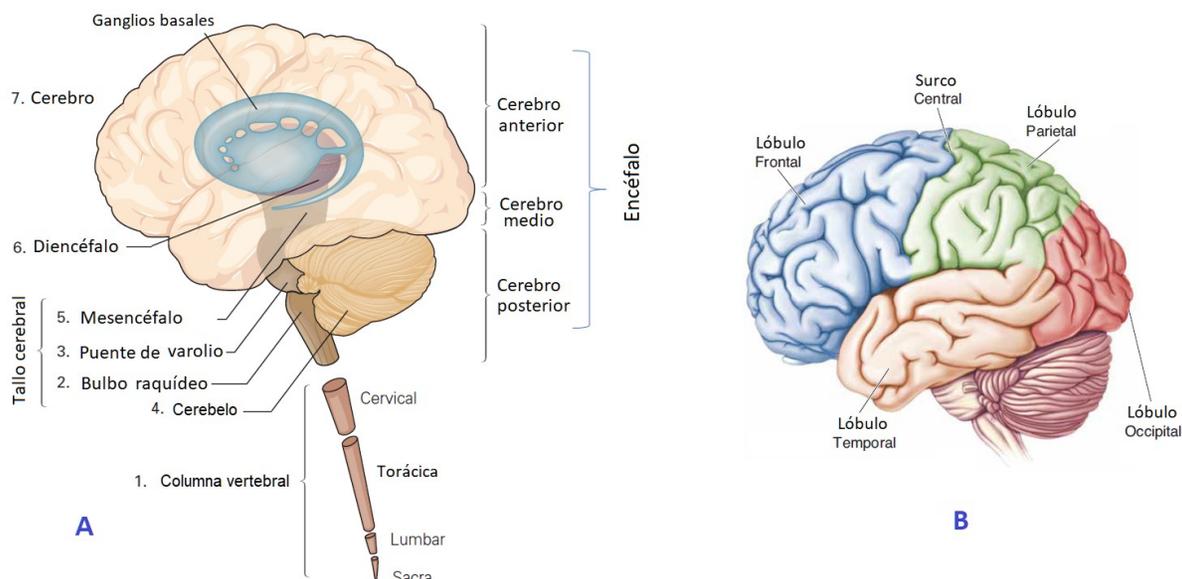


Figura 3.3. A) Las 7 partes principales del Sistema Nervioso Central [Kandel, 2013]. B) Lóbulos cerebrales [Bear, 2016]

3.4. El cerebro humano

En los países de habla inglesa se utiliza la palabra “*brain*” para referirse a la parte del sistema nervioso que están dentro del cráneo, que, junto con la columna vertebral, forman el sistema nervioso central (SNC). Sin entrar en detalles, este órgano llamado *brain*, se divide en “*cerebrum*”, “*brainstem*” y “*cerebellum*”, y no hay ninguna ambigüedad al respecto. Sin embargo, en países de habla hispana, en artículos, libros y bibliografía científica en general, e incluso en el traductor de “Google”, se equipara la palabra *brain* con la palabra “cerebro”, lo cual causa confusión, porque realmente la palabra equivalente es “encéfalo”, que atendiendo a sus raíces griegas, se interpreta como: “dentro de la cabeza”. En las fuentes mencionadas se utiliza la palabra *cerebro* indiscriminadamente para referirse al encéfalo, nombre que rara vez es mencionado. Realmente, el cerebro, también llamado telencéfalo, es parte del encéfalo. Siguiendo esta práctica tan extendida, el cerebro humano o encéfalo se divide en cerebro (telencéfalo, la parte más voluminosa), tallo cerebral (tallo o tronco encefálico) y cerebelo. El tallo cerebral se divide a su vez en mesencéfalo, puente de Varolio (protuberancia

anular o puente troncoencefálico) y bulbo raquídeo. Junto con el Diencefalo, se forman las siete partes principales del cerebro humano (encéfalo) Figura 3.3A.

El telencéfalo (el cerebro propiamente dicho), se divide en los hemisferios derecho e izquierdo (Figura 3.4A), cuya “corteza” externa constituye la “*corteza cerebral*” o “materia gris”, con forma laminar, que para maximizar su área y almacenar mayor número de neuronas con sus conexiones, dentro del cráneo, está empaquetada en circunvoluciones o pliegues formando surcos en su superficie. La parte más externa de la corteza cerebral corresponde al neocórtex, que como ya se mencionó, es la parte más evolucionada de la corteza cerebral donde se llevan a cabo mecanismos neuronales responsables de los niveles superiores de actividad mental humana, como la imaginación, el lenguaje, la inteligencia, la cognición, la memoria y el asiento de la conciencia.

La superficie externa del neocórtex en los dos hemisferios cerebrales se divide en áreas llamadas lóbulos: Frontal, temporal, parietal y occipital (Figura 3.3B). A principios del siglo XX el neuroanatomista alemán Brodmann, construyó un mapa de la *citoarquitectura* de la neocorteza cerebral (Figura 3.2B), donde muestra claramente que diferentes entradas sensoriales (motoras, somatosensoriales, visuales, auditivas, etc.) se asignan en áreas correspondientes de la corteza cerebral de manera ordenada. Brodmann adivinó, pero no pudo demostrar (lo que ahora se tiene evidencia), que las áreas corticales que se ven diferentes realizan funciones diferentes. Aunque esta idea fue propuesta primero por el neuroanatomista Franz Joseph Gall, cuyo trabajo considerado precientífico, es la piedra angular de los estudios modernos del cerebro. Hoy en día es común monitorear las actividades metabólicas del cerebro (con técnicas de neuroimagen) en condiciones controladas, mientras la persona realiza tareas específicas, lo que proporciona evidencia directa de que: tipos específicos de comportamiento involucran regiones particulares del cerebro. De esta manera, cada lóbulo tiene un conjunto especializado de funciones cerebrales, como se muestra en la Figura 3.4B.

Los hemisferios cerebrales similares en apariencia no son completamente simétricos en estructura ni equivalentes en función. Cada hemisferio se ocupa principalmente de los procesos sensoriales y motores en el lado opuesto del cuerpo, es

decir, la información sensorial que llega a la médula espinal desde el lado izquierdo del cuerpo cruza hacia el lado derecho del sistema nervioso para alcanzar la corteza cerebral.

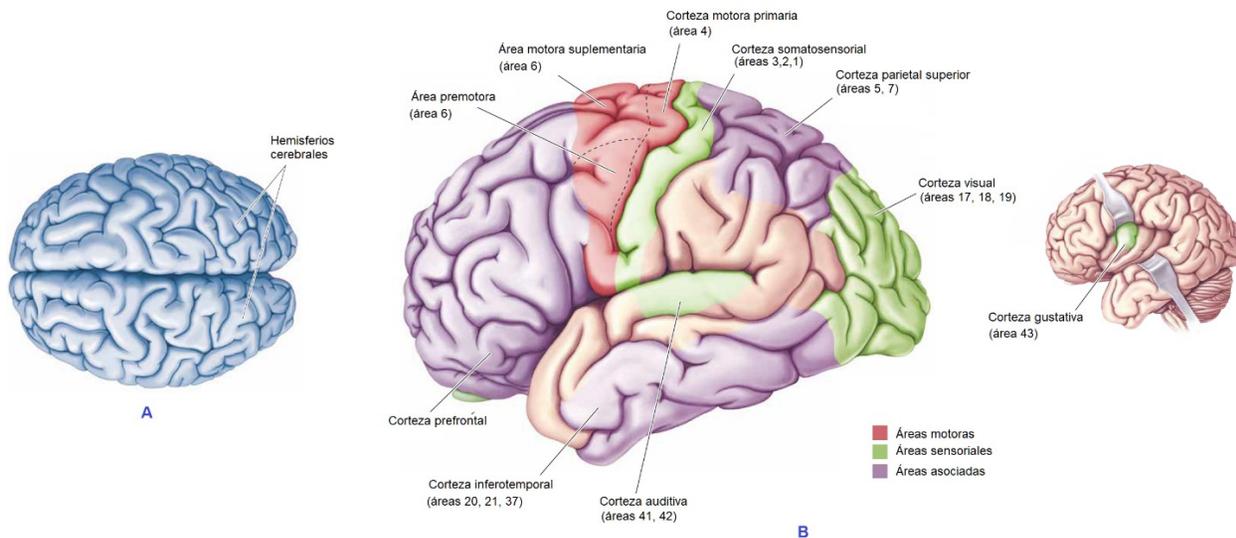


Figura 3.4. A) hemisferios cerebrales, B) funciones especializadas del cerebro [Bear, 2016]

De la misma manera, las áreas motoras en el hemisferio derecho ejercen control sobre los movimientos de la mitad izquierda del cuerpo.

El cerebro es la parte más importante del sistema nervioso que actúa como procesador central de información, realizando complejos cálculos neurales necesarios para extraer toda la información que continuamente recibe de los receptores y sensores, que convierten los estímulos del cuerpo humano o el ambiente externo en impulsos electroquímicos que transmiten información al cerebro, el cual toma las decisiones adecuadas y las envía a los efectores que convierten los impulsos electroquímicos generados por el cerebro, en respuestas discernibles a manera de salidas del sistema. En otras palabras, el cerebro organiza activamente la percepción, parte de la cual se almacena en la memoria para referencia futura, y parte de la cual se transforma en respuestas conductuales inmediatas.

El sistema nervioso puede ser visto como una vasta red de neuronas organizadas en una elaborada estructura con conexiones extremadamente complejas, que, de una forma básica, se comporta como un sistema de tres etapas (Figura 3.5), según lo descrito anteriormente, donde la dirección de transmisión de las señales portadoras de

información a través del sistema es de izquierda a derecha, mientras que la retroalimentación va de derecha a izquierda.



Figura 3.5. Representación esquemática básica del sistema nervioso con el cerebro como centro de control [Haykin, 2009] [Arbib, 1987]

El cerebro humano realiza operaciones neurales en el rango de milisegundos, mientras que una computadora digital lo hace en el rango de nanosegundos. Sin embargo, el cerebro compensa esta desventaja con un número asombroso de neuronas (10 billones) con interconexiones masivas entre ellas (60 trillones), en la corteza humana, es por esto que, es muchas veces más rápido en la solución de problemas que la más rápida computadora digital que existe hoy en día. Como ejemplo, de manera rutinaria, al cerebro humano le toma de 100 – 200 *ms* realizar el reconocimiento de la cara de una persona conocida en una escena poco familiar, mientras que tareas de mucho menos complejidad tomaría mucho más de ese tiempo una computadora convencional. La eficiencia energética del cerebro es aproximadamente de 10^{-16} Joules por operación por segundo, mientras que el correspondiente valor para la eficiencia de la mejor computadora es alrededor de los 10^{-6} Joules por operación por segundo. Debido a la propiedad de no linealidad de la neurona biológica, unidad estructural del sistema nervioso, el cerebro es un computador en paralelo altamente complejo, eficiente y no lineal. [Haykin, 1999] [Arbib, 1987] [Bear, 2016] [Kandel, 2013] [Churchland, 1986] [Gerstner-Kistler, 2014].

3.5. Células nerviosas

Las células nerviosas son las unidades estructurales básicas y de procesamiento de información en el sistema nervioso y, por ende, en el cerebro humano. De manera amplia, hay dos tipos de células nerviosas: las células gliales o glía, y las neuronas (sólo como referencia, dentro de estas categorías hay aproximadamente mil tipos de células nerviosas que difieren en estructura, química y función). Las células gliales superan en número a las neuronas, dado que hay 2^{10} veces más glía que neuronas en el sistema

nervioso central de los vertebrados. Las células gliales rodean a los cuerpos celulares, los axones y las dendritas de las neuronas, y aunque se dice que contribuyen a la función cerebral principalmente de sostén, aislando y nutriendo las neuronas vecinas, regulando el medio interneuronal del exceso de moléculas que intercambia la neurona con el exterior en el proceso de señalización eléctrica, e incluso actuando como sistema inmunitario atacando infecciones, lesiones y enfermedades de las neuronas, realmente hay una interrelación intrincada y esencial entre células glía y neuronas, de tal manera que la función extremadamente compleja de señalización neuronal en el sistema nervioso no sería posible sin la participación de las células gliales.

Atendiendo a su morfología (ver Figura 3.6), la neurona se divide en: dendritas, cuerpo celular o soma, axón y terminaciones presinápticas. Como toda célula, el cuerpo celular o soma es el centro metabólico de la célula. Contiene el núcleo, que a su vez contiene los genes de la célula, además del retículo endoplásmico donde se sintetizan las proteínas de la célula, que son esenciales para los procesos moleculares llevados a cabo dentro de la misma, para que ésta cumpla su función de señalización (Sección 3.7).

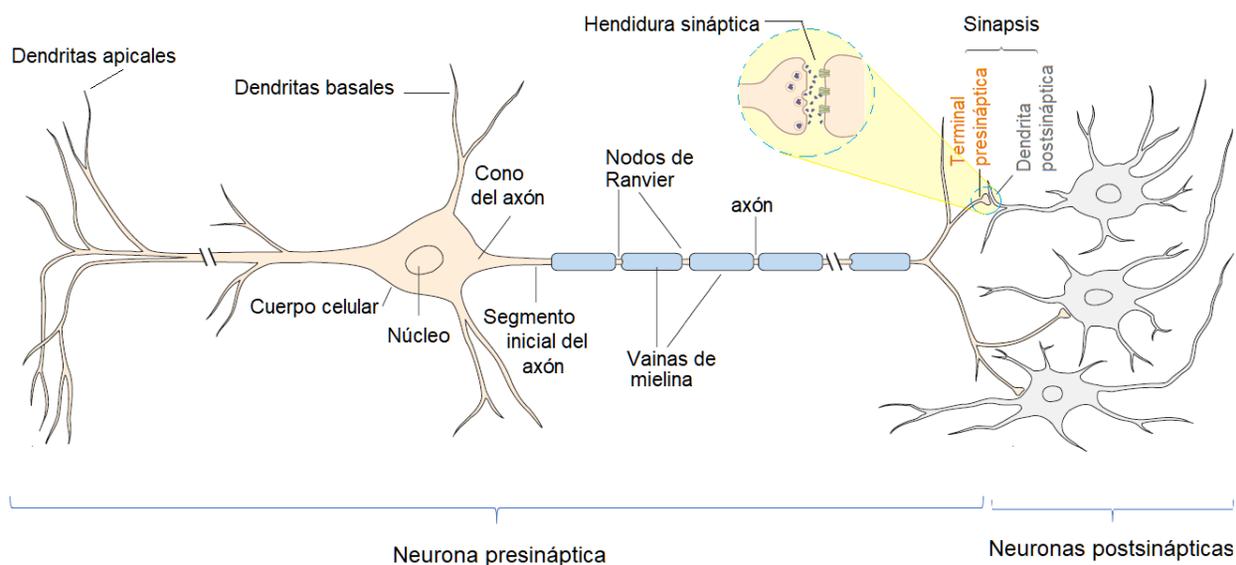


Figura 3.6. Partes de la neurona. Neuronas presinápticas y postsinápticas [Kandel, 2013]

Las dendritas tienen ramificaciones en forma de árbol y son el principal aparato de recepción de señales procedentes de otras neuronas. Las señales eléctricas se transmiten a través del axón a otras neuronas a distancias que van desde 0.1 mm a 2 m.

El extremo terminal del axón se divide en ramas o filamentos finos llamados *terminales presinápticas* con los cuales se comunican con las *neuronas postsinápticas* en zonas especializadas de comunicación conocidas como *sinapsis*. Las células presinápticas y postsinápticas están separadas por un espacio muy estrecho llamado hendidura sináptica. La comunicación sináptica puede ser de origen químico (en la mayoría de las veces) o eléctrico.

Para aumentar la velocidad de la señal eléctrica en axones finos y largos, se envuelven (por medio de células gliales) en una sustancia lipídica aislante llamada *vaina de mielina*, que se interrumpe a intervalos regulares por los *nodos de Ranvier*, puntos no aislados en el axón donde se regenera la señal eléctrica.

Según su funcionalidad, las neuronas se clasifican en: *neuronas sensoriales*, *neuronas motoras* e *interneuronas* (Figura 3.7).

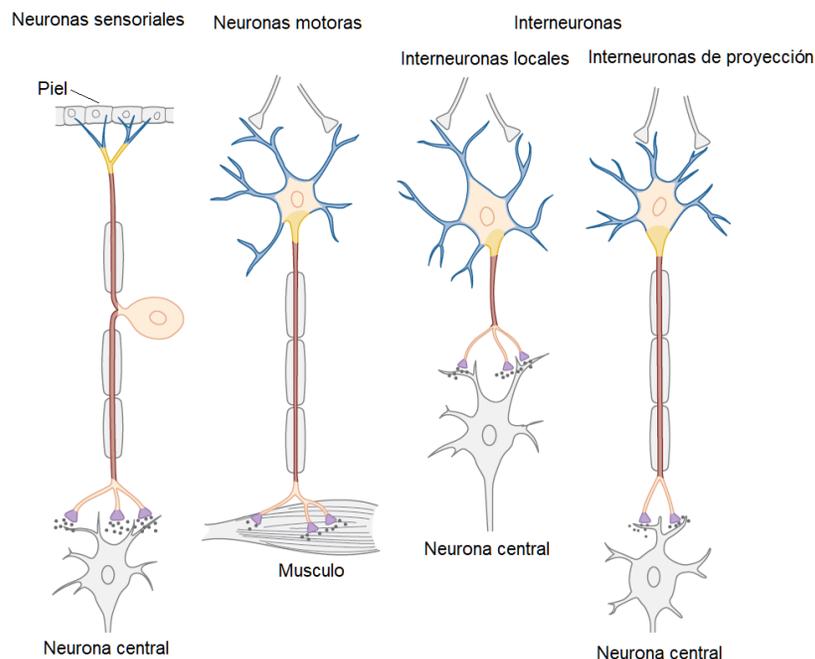


Figura 3.7. Tipos de neuronas según su función. [Kandel, 2013]

Las neuronas sensoriales transmiten información (información aferente) desde los sensores periféricos del cuerpo al sistema nervioso con el propósito tanto de percepción como de coordinación motora. Las neuronas motoras llevan información desde el cerebro o la médula espinal a los músculos y las glándulas (información eferente). Las

interneuronas pueden ser de *retransmisión (proyección)* o *locales*. Las primeras tienen axones largos y finos y retransmiten señales a distancias de una región a otra del cerebro. Las locales, de axones cortos forman conexiones con las neuronas cercanas. Las interneuronas pueden actuar como neuronas *inhibitorias* en casos de movimientos agónicos y antagónico, por ejemplo, la flexión y extensión de una pierna involucra músculos extensores y flexores. La pierna extendida implica la inhibición de músculos flexores y la activación de músculos extensores, y viceversa. El caso mencionado que es un típico patrón de conexión, en el que una neurona activa muchas células objetivo, se llama divergencia (*fan out*). Por ejemplo, la información sensorial de un sólo sitio se distribuya más ampliamente en la médula espinal y el cerebro. El patrón de conexión cuando una sola célula motora recibe muchos contactos de entrada de células sensoriales se llama convergencia (*fan in*). La convergencia asegura que una neurona motora se active sólo si un número suficiente de neuronas sensoriales se activan juntas [Arbib, 1987] [Haykin, 1999] [Bear, 2016] [Kandel, 2013] [Gerstner-Kistler, 2014].

3.6. Potencial de acción

Hay una gran variedad y cantidad de estímulos del medio ambiente que impresionan nuestros sentidos sensoriales, así como de todo organismo que posee un sistema nervioso: la luz que incide en nuestros ojos y que permite distinguir muchos colores y formas, el contacto mecánico que crea sensaciones en nuestra piel: de suavidad, aspereza, presión, dolor, etc. Los diferentes olores, sabores y sonidos que nos crean sensaciones de placer o disgusto, etc. Todo este torrente de información recibida por nuestros sentidos sensoriales es transmitido al cerebro de una única manera: mediante señales eléctricas llamadas **Potenciales de Acción** producidas dentro de las neuronas del sistema nervioso. El potencial de acción es la unidad elemental de transmisión de señalización en el sistema nervioso. Los potenciales de acción se originan en el segmento inicial del axón una región especializada de disparo (la zona de activación, ver Figura 3.9) y se propagan a lo largo del axón de la neurona sin presentar fallas ni distorsión a velocidades que van de 1 a 100 m / s .

A pesar de la gran variedad de estímulos sensoriales que recibe un organismo, el tipo y forma del potencial de acción (Figura 3.8), es altamente estereotipado (variando sólo sutilmente de una neurona a otra) en todo el sistema nervioso, es decir, el tipo de

señales que transmiten información sobre la visión es idéntica a las que transmiten información sobre sonidos, por ejemplo. Esta invariabilidad de la señal eléctrica deja entrever un principio clave en la manera en cómo se organiza el cerebro: la información transmitida por un potencial de acción está determinada no por la forma de la señal, sino por el tipo de circuito neuronal que recorre la señal en el cerebro. Este principio organizativo del cerebro en circuitos anatómicos con funciones y propiedades similares precisas es lo que determina la complejidad del sin número de facetas que conforman el comportamiento humano, el cual depende no en la variedad de neuronas y forma de la señal que producen, sino en la manera en la que están interconectadas. Los potenciales de acción son el medio por el cual el cerebro recibe, analiza e interpreta los patrones de las señales eléctricas entrantes y los circuitos neuronales que recorren, y crea de esta manera, nuestras sensaciones de vista, tacto, olfato y sonido, por ejemplo.

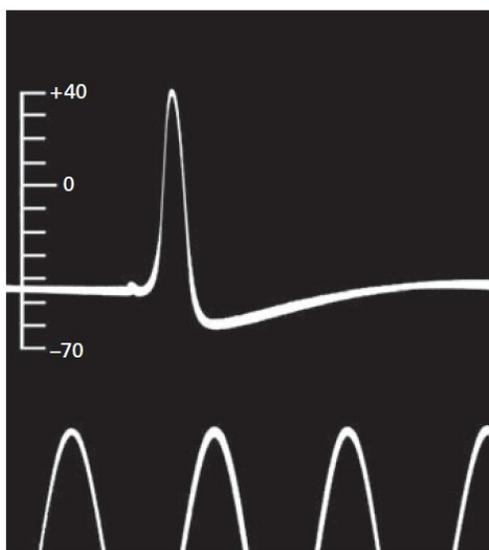


Figura 3.8. Este trazo histórico es el primer registro intracelular de la forma de un potencial de acción a lo largo del axón gigante de calamar obtenido por Hodgkin y Huxley en 1939, en sus estudios rumbo al modelo matemático de la neurona biológica. La escala vertical está en milivoltios, y la escala horizontal en pulsos de tiempo [Kandel, 2013] [Hodgkin-Huxley, 1939]

En la mayoría de las neuronas [Kandel, 2013], lo cual puede explicarse con una neurona modelo (Figura 3.9) que las ejemplifique a todas; para la generación de un potencial de acción se requieren de cuatro componentes que involucra cuatro zonas diferentes: 1) Un **Componente de Recepción de la Señales**, en la **Zona de Entrada**, formada por cada una de las dendritas del cuerpo celular. 2) Un **Componente Sumador**

o **Integrador** que evalúa el balance del total de entradas (que pueden ser excitadoras o inhibitoras) y que envía el resultado a la **Zona de Activación o Zona de Disparo** que se encuentra en la zona inicial del axón. Si el resultado de este balance alcanza un cierto **Valor de Umbral** impuesto por la misma neurona, entonces se genera la señal eléctrica o potencial de acción que corre a lo largo del 3) **Componente de Conducción de Señalización** o axón. Cuando la señal eléctrica o potencial de acción alcanza 4) el **Componente Secretor** (terminales presinápticas), se libran sustancias químicas llamadas **neurotransmisores** en la hendidura sináptica (**Zona de Salida**). Los neurotransmisores, formados por moléculas orgánicas, como L-glutamato y acetilcolina, o péptidos como la sustancia P o LHRH (hormona liberadora de la hormona luteinizante), son captados por receptores especializados en la neurona postsináptica, desencadenando señales eléctricas en sus dendritas llamadas **potenciales sinápticos** cuya intensidad depende de la cantidad de neurotransmisor liberado, lo que inicia nuevamente el proceso de creación de potencial de acción.

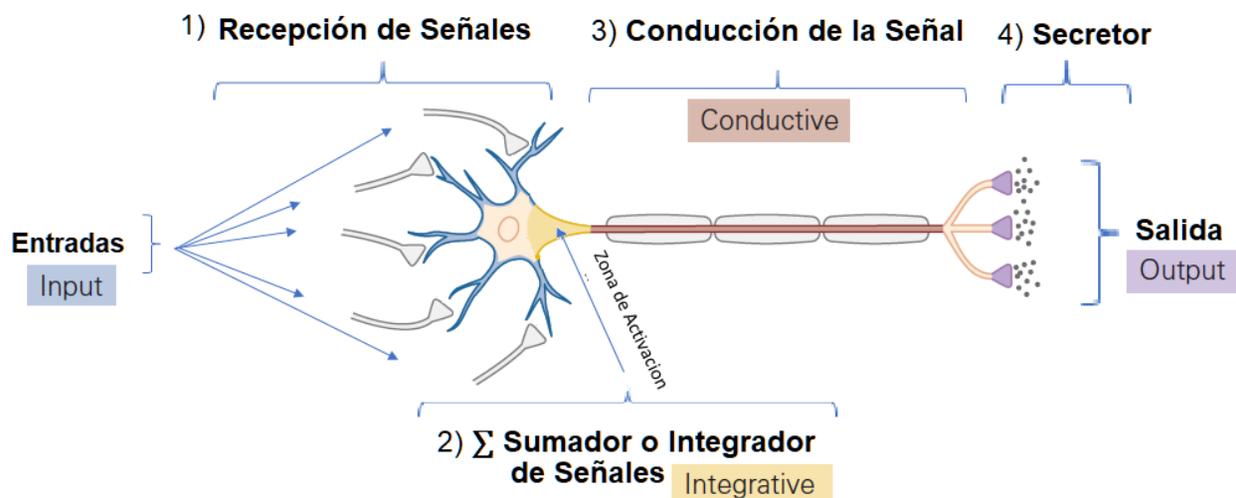


Figura 3.9. Una Neurona Modelo tiene cuatro Componentes involucrados en la Generación de Potenciales de Acción [Kandel, 2013]

De acuerdo con lo anterior, la señalización en el sistema nervioso es de origen electroquímico, porque comprende el origen de señales eléctricas dentro de las neuronas, las cuales causan la liberación de sustancias químicas (neurotransmisores) en las terminales presinápticas, aparte de toda la bioquímica involucrada en el origen fundamental de los potenciales de acción, que descansa en procesos de intercambio molecular entre el interior de la célula nerviosa y su entorno inmediato, gracias a las

características funcionales de la membrana celular. Se dice que el potencial de acción es de naturaleza **todo o nada**, porque los estímulos por debajo del umbral no producen un potencial de acción, no así los estímulos que sean iguales, o que estén por encima del umbral, que producen potenciales de acción de la misma amplitud y forma de onda. Mientras el resultado del componente sumador de la neurona alcance, sobrepase por poco o mucho el valor de umbral, la amplitud y duración de cada potencial de acción es más o menos la misma. El potencial de acción no decae a medida que viaja a lo largo del axón hasta su objetivo, que puede ser una distancia tan grande como $2m$, porque se regenera periódicamente en cada nodo de Ranvier. Esta señal conductora puede viajar a velocidades de hasta $100 m / s$, y tener una amplitud de $100 mV$.

Dado que los potenciales de acción conservan la misma forma de onda y amplitud, no transportan información codificada [Kandel, 2013] [Gerstner-Kistler, 2014]. Es decir, los potenciales de acción transportados en el sistema nervioso por una neurona sensorial son indistinguibles de los potenciales de acción transportados a los músculos del sistema nervioso por una neurona motora. La información se transmite por cadenas de potenciales de acción emitidos por las neuronas llamados trenes de pulsos (de espigas, de picos o de *spikes*), que son una secuencia de eventos estereotipados que ocurren a intervalos regulares o irregulares. Las dos características de transmisión son: el número de potenciales de acción y los intervalos de tiempo entre ellos (Figura 3.10). Dicho de otra manera: si los potenciales de acción están abarrotados (muy pegados unos de otros en tiempo), la sensación es intensa, si están separados por largos intervalos de tiempo, la sensación es débil. Por lo tanto, lo que determina la intensidad de la sensación o movimiento es la frecuencia de los potenciales de acción. Asimismo, la duración de una sensación o movimiento está determinada por el período durante el cual se generan potenciales de acción [Kandel, 2013].

El patrón de potenciales de acción también transmite información importante. Por ejemplo, algunas neuronas son espontáneamente activas y disparan potenciales de acción regularmente (modo rítmico o *beating mode*); otras neuronas se disparan en breves estallidos de potenciales de acción (modo de estallido o *bursting mode*). Esta variedad de neuronas responde de manera diferente a la misma entrada sináptica excitatoria. Un potencial sináptico excitatorio puede iniciar uno o más potenciales de

acción en una célula que no tiene una actividad espontánea, pero en las células espontáneamente activas esa misma entrada modulará el ritmo al aumentar la velocidad de activación de los potenciales de acción. En la Figura 3.10 se puede observar diferentes patrones de actividad de potenciales de acción en diferentes células nerviosas del cerebro. Figura 3.10A: Tren de potenciales de acción que disminuye en frecuencia. Este patrón de actividad se conoce como disparo regular. Algunas células corticales generaron ráfagas de tres o más potenciales de acción. Figura 3.10B: Las células Purkinje del cerebelo generan trenes de alta frecuencia de potenciales de acción en sus cuerpos celulares. Figura 3.10C: Las neuronas de relé talámica generan potenciales de acción en ráfagas o trenes tónicos de potenciales de acción. Figura 3.10D: Las neuronas habenulares medulares generan potenciales de acción a un ritmo constante y lento, en forma de marcapasos.

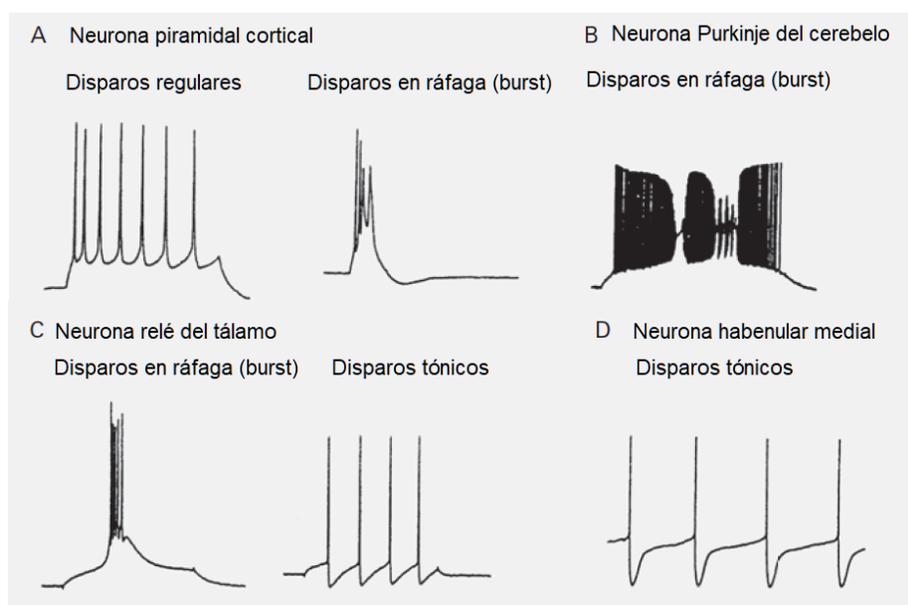


Figura 3.10. Variedad de patrones de potenciales de acción en neuronas del cerebro humano [Kandel, 2013]

De lo anterior, se pueden distinguir cuatro propiedades importantes de los potenciales de acción en la señalización neuronal. 1) Tienen un umbral para la iniciación, 2) El potencial de acción es un evento de todo o nada, es decir, la única condición para activar un potencial de acción, en la que conserva su forma y tamaño, es que iguale o supere el umbral, 3) El potencial de acción se lleva a cabo sin disminución. Tiene una función autorregenerativa (en los nodos de Ranvier) que mantiene constante la amplitud,

incluso cuando se desplaza grandes distancias, 4) El potencial de acción es seguido por un *período refractario*, en el que se suprime la capacidad de la neurona para disparar un segundo potencial de acción por un periodo corto de tiempo. Esto limita la frecuencia con la que una neurona puede disparar potenciales de acción y, por lo tanto, también la capacidad de transmitir información.

Estas cuatro propiedades del potencial de acción (umbral de iniciación, naturaleza de todo o nada, conducción sin decremento y período refractario) son inusuales para los procesos biológicos, que generalmente responden de manera gradual a los cambios en el medio ambiente, lo que impactó a los científicos de hace cien años.

Referencias de esta sección: [Kandel, 2013] [Bear, 2016] [Gerstner-Kistler, 2014] [Izhikevich, 2007] [Hodkin-Huxley, 1939] [Dayan-Abbott, 2001].

3.7. La membrana neuronal

La membrana plasmática [Kandel, 2013] [Bear, 2016], la envoltura que define los límites físicos entre el interior y el exterior de todas las células biológicas, incluidas las células nerviosas, tiene un grosor aproximado de 6 a 8 *nm*, y por medio de ella la célula intercambia diferentes sustancias con el medio circundante con el cual interactúa con diferentes propósitos, uno de los cuales es mantener su funcionalidad como unidad estructural de la vida. La membrana plasmática regula tanto las sustancias que entran a su interior (nutrientes, entre otros), como las que salen (desechos metabólicos, entre otros), por eso se dice que la membrana es *permeable* sólo a un selecto tipo de sustancias que le ayudan a mantener su integridad, y la función que desempeña.

El interior neuronal (Figura 3.11), lo constituye el protoplasma formado por el núcleo y el citoplasma. El citoplasma celular es el medio en el cual flota el núcleo y diferentes organelos. Contiene dos componentes principales: el citosol y orgánulos membranosos. El citosol es la fase acuosa del citoplasma que además de servir como vehículo de sustancias nutritivas para la célula, contiene unas pocas proteínas libres en la solución, y otras más se organizan en complejos funcionales, con la excepción de algunas enzimas que catalizan reacciones metabólicas. Contiene los ribosomas, estructuras proteicas que se encargan de la expresión génica, así como las proteasomas, grandes orgánulos multienzimáticos que degradan cierto tipo de proteínas. Las

mitocondrias y peroxisomas, así como el aparato vacuolar formado por un complejo sistema de túbulos, vesículas, el retículo endoplásmico rugoso, el retículo endoplásmico liso, el aparato de Golgi, vesículas secretoras, endosomas, lisosomas y una multiplicidad de vesículas de transporte que interconectan estos diversos compartimentos, todos ellos forman los orgánulos membranosos, el segundo componente principal del citoplasma. Las mitocondrias elaboran el trifosfato de adenosina (ATP), paquetes moleculares de energía utilizadas para el gasto celular. Las mitocondrias y los peroxisomas procesan el oxígeno molecular.

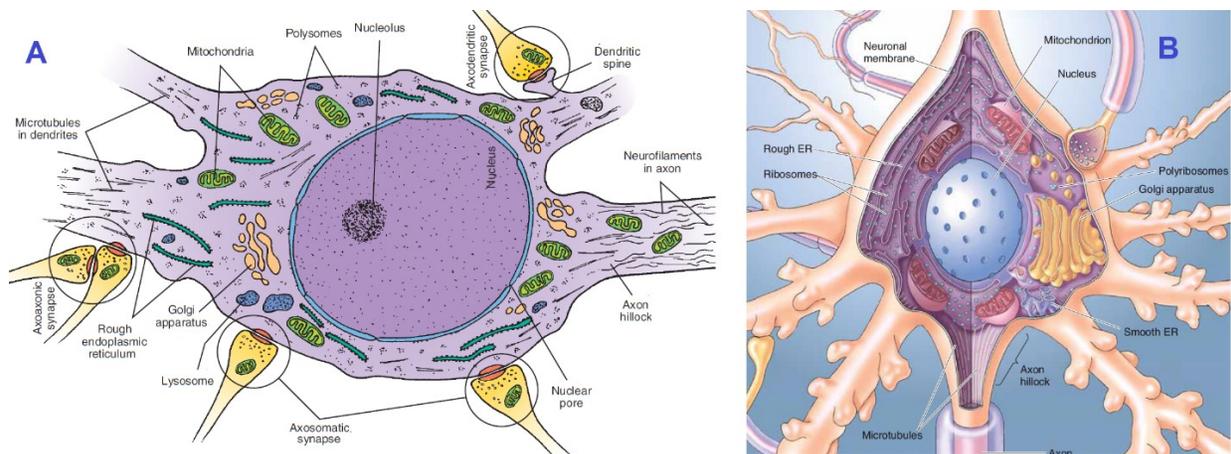


Figura 3.11. Algunos componentes del interior de la neurona. A) [Kiernan, 2014], B) [Bear, 2016]

Una porción especializada del retículo endoplásmico rugoso forma la envoltura nuclear, una cisterna aplanada esférica que rodea el ADN cromosómico y sus proteínas asociadas lo que define el núcleo celular. La envoltura nuclear es interrumpida por poros nucleares, canales hidrofílicos a través de los cuales se intercambian proteínas y ARN entre el citoplasma celular y el citoplasma nuclear. El citoplasma del cuerpo de la célula nerviosa se extiende hacia el árbol dendrítico sin diferenciación funcional. En general, todos los orgánulos en el citoplasma del cuerpo celular también están presentes en las dendritas en menor densidad. Los ribosomas, lisosomas, el retículo endoplásmico rugoso y el complejo de Golgi: los orgánulos que comprenden la maquinaria biosintética principal para las proteínas en la neurona, generalmente se excluyen de los axones. Sin embargo, los axones son ricos en vesículas sinápticas.

El agua es el ingrediente principal tanto del líquido dentro de la neurona, líquido intracelular o citosol, como del líquido exterior o líquido extracelular que baña la neurona.

Debido a la mayor afinidad electrónica del oxígeno respecto al hidrogeno en la molécula de agua (H_2O), se crea una distribución polarizada y desigual de la carga eléctrica, convirtiendo a las moléculas de agua en dipolos que se unen por atracción eléctrica en una configuración llamada *punte de hidrogeno*, propiedad que hace del agua un medio efectivo para que otras moléculas polares puedan disolverse en ella, como algunas sales, alcoholes, azúcares, aminoácidos, proteínas etc., lo que da lugar a disoluciones moleculares. Las sustancias salinas se disocian formando iones, es decir, átomos con carga eléctrica positiva (cationes) o negativa (aniones), como es el caso de la molécula de sal común, el cloruro de sodio $NaCl$, que se disocia en agua en átomos de sodio Na^+ y cloro Cl^- , o el cloruro de potasio KCl , que se disocia en átomos de potasio K^+ y cloro Cl^- , y en general las sales de potasio de la forma KA se disocian como el catión K^+ y el anión A^- (una molécula con carga negativa). Los iones disociados se rodean de *aguas de hidratación* (moléculas de agua) debido a su carga eléctrica, por eso se dice que los iones son *hidrófilos* (les atrae el agua).

Específicamente, la membrana o plasmalema de las neuronas (Figura 3.12), está formada por una asimétrica doble capa de fosfolípidos, que proporciona una barrera hidrófoba (no se mezcla con el agua) impermeable a la mayoría de las sustancias solubles en agua y al agua misma, pero precisamente, la permeabilidad de la membrana consiste en la existencia de conductos que atraviesan la membrana celular llamados *canales*, por donde se realiza el intercambio de sustancias entre el interior y exterior de la célula. Los canales no son simples agujeros en la membrana lipídica, sino que son estructuras complejas formadas de distintas proteínas y que abarcan la bicapa lipídica. Las *acuaporinas* son canales que facilitan el movimiento de agua a través de la membrana celular, por lo que se dice que la membrana es permeable al agua. Pero la señalización en el sistema nervioso recae en la naturaleza eléctrica de la membrana neuronal, responsable del origen del potencial de acción, gracias a la existencia de diversos y complejos canales iónicos selectivos a ciertos tipos de iones que se encuentran disueltos tanto en el interior como en el exterior de la célula nerviosa. Los iones son los principales portadores de carga en la conducción de electricidad en los sistemas biológicos, como la neurona.

Los iones de particular importancia para la neurofisiología celular son los cationes monovalentes: sodio (Na^+) y potasio (K^+), el catión divalente calcio (Ca^{2+}), el anión monovalente cloro (Cl^-) y de menor trascendencia, el magnesio (Mg^{2+}), entre otros. De entre ellos, los más importantes en la señalización eléctrica son: Na^+ , K^+ , Cl^- y Ca^{2+} .

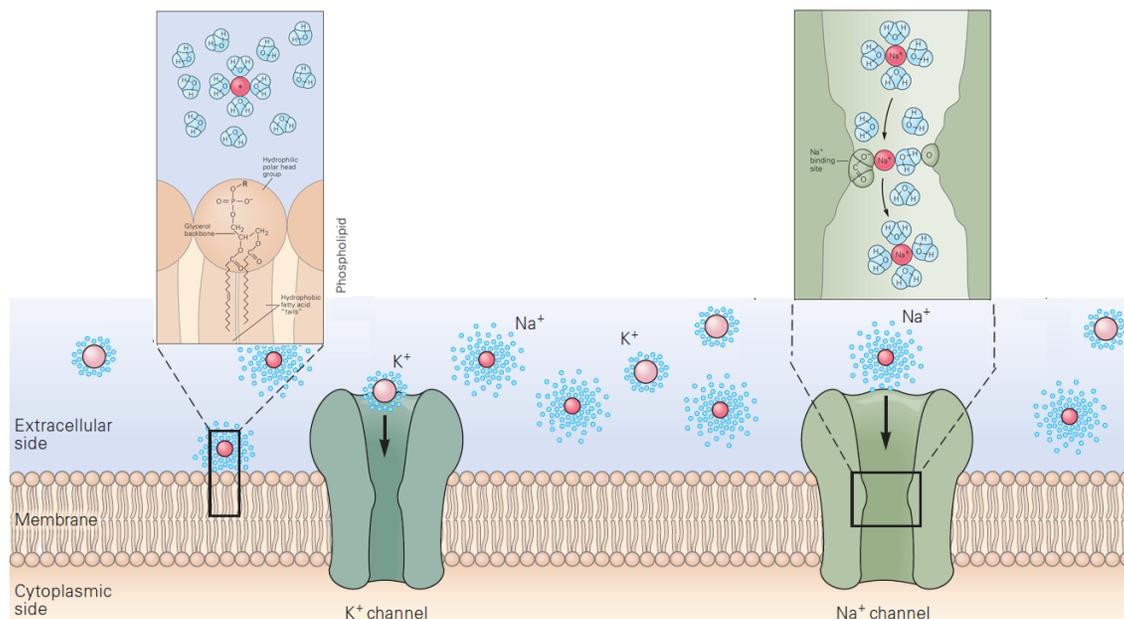


Figura 3.12. Membrana neuronal compuesta por una doble capa de fosfolípidos y diversos canales iónicos. Alrededor de los iones se forman “aguas de hidratación” [Kandel, 2013]

La selectividad de los canales respecto a los iones que los cruzan es muy compleja. Algunos canales permiten el cruce indiscriminado de una variedad de iones (cationes) muy comunes, como Na^+ , K^+ y Ca^{2+} . Otros canales sólo son permeables a un sólo tipo de los cationes mencionados. Respecto a la permeabilidad de aniones, sólo conducen el ion fisiológico cloro (Cl^-).

La dinámica de iones a través de canales iónicos se sustenta principalmente en potenciales electroquímicos, debidos a la diferencia de potencial eléctrica y/o por gradientes de concentración (difusión) de los diferentes iones, entre ambos medios internos y externos de la neurona. Se dice que el movimiento de iones por medios electroquímicos es pasivo porque no requiere de gasto de energía, sin embargo, no se puede permitir que esta fuga constante de iones continúe sin oposición durante un período de tiempo apreciable porque los gradientes de los iones importantes, causantes de las propiedades eléctricas de la neurona, eventualmente disminuirán. Para

restablecer y mantener los gradientes de concentración de iones fisiológicamente importantes entre el interior y el exterior de la célula, hay un segundo tipo de canales iónicos para mover iones a través de las membranas celulares en oposición a sus gradientes electroquímicos: Las *bombas*, los *transportadores* y *cotransportadores*, los cuales requieren de gasto de energía por parte de la célula (ATP), aunque estas proteínas no participan en la señalización neuronal rápida. A estos movimientos iónicos que requieren energía se les denomina *transporte activo*. Dos bombas de iones son especialmente importantes en la neurofisiología celular: la bomba de sodio-potasio y la bomba de calcio.

Para optimizar la conducción eléctrica a través de la membrana, muchos canales son activados (abiertos) por diferentes estímulos, como: voltaje, temperatura, por medios mecánicos, por “*ligandos*” químicos, que son mecanismos tipo “cerradura”, donde “se requiere una cierta llave para abrir una determinada cerradura”, o también por liberación de neurotransmisores relacionados con los potenciales sinápticos. Esta clase de activación de los canales iónicos son llamados de “*control de compuerta*” (*gating-channels*), y tienen por lo menos un estado de abierto y uno o dos estados de cerrado.

Como se mencionó, el flujo de iones a ambos lados de la membrana es el resultado de la acción de dos fuerzas que los conducen a través de la membrana: 1) una fuerza impulsora química, debido a su gradiente de concentración, y 2) una fuerza impulsora eléctrica, debida a la diferencia de potencial eléctrico a través de la membrana. Cuando estas dos fuerzas se equilibran la membrana adquiere un potencial eléctrico, llamado potencial de membrana en reposo, que es como una especie de promedio de los potenciales de equilibrio de cada una de las especies iónicas involucradas. El potencial de equilibrio E_X , o potencial de reposo o potencial de Nernst, de cualquier especie iónica X , fue derivado por el Químico-Físico Walter Nernst y está dado por:

$$E_X = \frac{RT}{zF} \ln \frac{[X]_o}{[X]_i} \quad (3.1)$$

donde R es la constante del gas, T la temperatura (en grados Kelvin), z la valencia del ion, F la constante de Faraday, $[X]_o$ y $[X]_i$ son las concentraciones del ion fuera y dentro de la neurona respectivamente. Dado que RT/F es de 25 mV a 25° C (77° F ,

temperatura ambiente), y convirtiendo a logaritmos de base 10, se puede poner la ecuación anterior en forma *simplificada* como (3.2).

$$E_X = \frac{58mV}{z} \log \frac{[X]_o}{[X]_i} \quad (3.2)$$

En el potencial de reposo se crea una separación de carga a cada lado de la membrana en forma de nubes finas de iones positivos y negativos que se extienden sobre su superficie interna y externa (Figura 3.13).

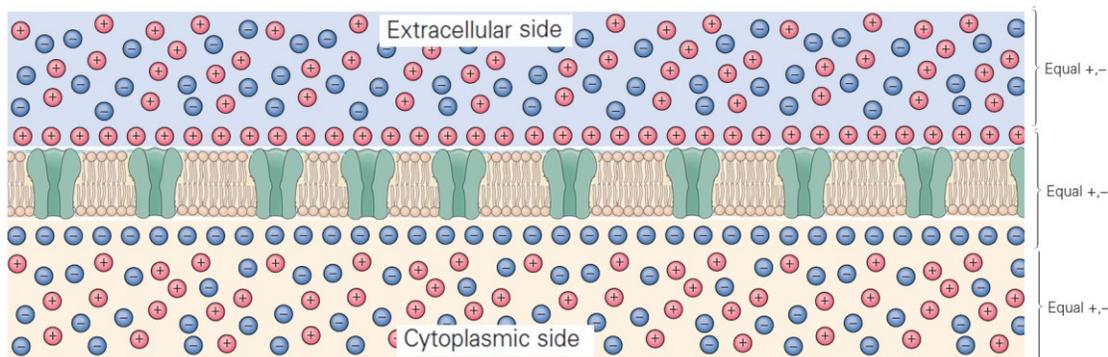


Figura 3.13. En el potencial de reposo se crea una separación de carga a cada lado de la membrana en forma de nubes finas de iones positivos y negativos que se extienden sobre su superficie interna y externa [Kandel, 2013]

La superficie extracelular tiene un exceso de carga positiva y la superficie citoplasmática un exceso de carga negativa. En cualquier momento, la diferencia de potencial eléctrico, o voltaje, a través de la membrana se le llama potencial de membrana V_m , y se define como $V_m = V_{in} - V_{out}$ donde V_{in} es el potencial en el interior y V_{out} el potencial en el exterior de la neurona. Por convención, el voltaje fuera de la membrana se define como cero, así, $V_m = V_{in}$. En el reposo, el potencial de membrana corresponde al potencial de reposo, por lo tanto: $V_m = V_{in} = V_r$. En una neurona en reposo típica, el voltaje del interior de la célula es aproximadamente $65 mV$ más negativo que el voltaje fuera de la célula, por lo que se dice que su potencial de membrana en reposo es $V_r = -65 mV$. En general, el potencial de reposo varía de $-40 a -80 mV$ para diferentes células nerviosas, alcanzando hasta, aproximadamente $-90 mV$ en las neuronas musculares.

El potencial de membrana en reposo resulta de la distribución desigual de iones con carga eléctrica, en particular los iones de Na^+ y K^+ con carga positiva, y de la permeabilidad selectiva de la membrana. De los cuatro iones más abundantes que se

encuentran a ambos lados de la membrana celular, Na^+ y Cl^- se concentran fuera de la neurona y dentro de ella, K^+ y aniones orgánicos (A^- , principalmente aminoácidos y proteínas). Además, hay un movimiento pasivo de K^+ fuera de la célula en reposo a través de canales abiertos que equilibra el movimiento pasivo de Na^+ hacia la célula. Por lo tanto, en el potencial de membrana en reposo, la neurona no está en equilibrio, sino más bien en un estado estable: La entrada pasiva continua de Na^+ y el flujo de salida de K^+ a la neurona a través de canales en reposo están exactamente contrarrestados por las bombas de sodio-potasio ($Na^+ - K^+$).

El potencial de membrana V_m se puede calcular mediante la ecuación de Goldman:

$$V_m = \frac{RT}{F} \ln \frac{P_K[K^+]_o + P_{Na}[Na^+]_o + P_{Cl}[Cl^-]_o}{P_K[K^+]_i + P_{Na}[Na^+]_i + P_{Cl}[Cl^-]_i} \quad (3.3)$$

donde las constantes que aparecen son las mismas de la ecuación (3.1). También participan las concentraciones de las especies iónicas involucradas, así como su permeabilidad P , definida como la facilidad para cruzar la membrana lipídica, que observa unidades de velocidad en cm/s . Cuando un ion en particular es muy abundante en comparación con el resto, la ecuación anterior se reduce al potencial de Nernst para ese ion, por esta razón el potencial de membrana en el reposo se acerca mucho al potencial de Nernst para el potasio, en cambio en el pico del potencial de acción, el potencial de membrana se acerca mucho al potencial de Nernst para el sodio, pero no se da la igualdad debido a la leve interacción del resto de especies iónicas.

En la neurona en reposo no hay movimiento de carga neta a través de la membrana. Cuando hay un flujo neto de cationes o aniones dentro o fuera de la neurona debido a estímulos provenientes de otras neuronas, se altera la separación de carga a través de la membrana en reposo, alterando consecuentemente el potencial de membrana. Una disminución en la separación de carga, que conduce a un potencial de membrana menos negativo, se llama *despolarización*. Un aumento en la separación de carga, que conduce a un potencial de membrana más negativo, se llama *hiperpolarización*. Las respuestas hiperpolarizantes son casi siempre pasivas, al igual que las pequeñas despolarizaciones. Sin embargo, cuando la despolarización se acerca a un nivel crítico, o umbral, la célula responde activamente con la apertura de canales

iónicos activados por voltaje, que al alcanzar el umbral se produce un potencial de acción de todo o nada. Los cambios en el potencial de membrana que no conducen a la apertura de canales iónicos de “control de compuerta” se denominan potenciales electrotónicos. Referencias para esta sección: [Kandel, 2013] [Bear, 2016] [Gerstner-Kistler, 2014] [Kiernan, 2014] [Dayan-Abbott, 2001].

3.8. Modelo matemático neuronal de Hodgkin-Huxley

Hodgkin y Huxley realizaron una extensa serie de experimentos en el axón gigante del calamar y lograron medir las corrientes que pasan a través de canales iónicos en su membrana celular, y describieron su dinámica en términos de ecuaciones diferenciales. De su artículo publicado en 1952, se dice que presenta una “bella teoría matemática y elegantes experimentos”, que condujeron a que ambos científicos recibirán el premio nobel de fisiología 1963.

Alan Hodgkin y Andrew Huxley desarrollaron la primera descripción completa de los mecanismos iónicos subyacentes al potencial de acción, mediante estudios realizados en el axón gigante del calamar utilizando una técnica de *fijación de voltaje* desarrollada por Kenneth Cole en 1949. Kenneth Cole y Howard Curtis realizaron un estudio temprano importante sobre cómo se generan los potenciales de acción en el axón gigante del calamar, en el que descubrieron que la conductancia iónica a través de la membrana aumenta de manera dramática durante el potencial de acción. Este descubrimiento proporcionó la primera evidencia de que el potencial de acción resulta de cambios en el flujo de iones a través de canales en la membrana.

Hodgkin y Huxley postularon que las permeabilidades de Na^+ y K^+ , estaban reguladas directamente por el potencial de membrana. Para probar esta hipótesis, variaron sistemáticamente el potencial de membrana en el axón gigante de calamar y midieron los cambios resultantes en la *conductancia* de los canales de Na^+ y K^+ dependientes de voltaje. Para ello, utilizaron la técnica de fijación de voltaje (voltage-clamp). Esta técnica permite mantener constante el potencial de membrana generando una cantidad de corriente que proporciona una medida directa de la corriente que fluye a través de la membrana, lo que permite analizar por separado los componentes iónicos y *capacitivos* de la corriente de membrana. Las mediciones de estas corrientes iónicas

se pueden usar para calcular la dependencia del voltaje y del tiempo, de los cambios en la conductancia de la membrana causados por la apertura y cierre de los canales de Na^+ y K^+ , lo que proporciona información sobre las propiedades de estos dos tipos de canales. Por ejemplo, si se aplica una etapa de despolarización de 10 mV , fluye una corriente capacitiva I_c saliente proporcional a una despolarización de 10 mV , seguida por otra corriente saliente más pequeña, constante durante la etapa de fijación voltaje. Esta corriente (corriente de fuga I_l) fluye a través de los canales iónicos en reposo no controlados de la membrana (canales de fuga). La conductancia total de esta población de canales es la conductancia de fuga g_l . Al final del paso o etapa, una breve corriente capacitiva entrante repolariza la membrana a su voltaje inicial y la corriente total de la membrana vuelve a cero (Figura 3.14).

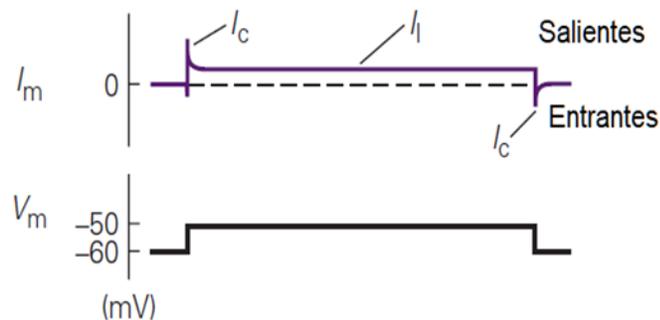


Figura 3.14. Una pequeña despolarización provoca una corriente capacitiva I_c y una corriente de fuga I_l que conforman la corriente de membrana total I_m [Kandel 2013]

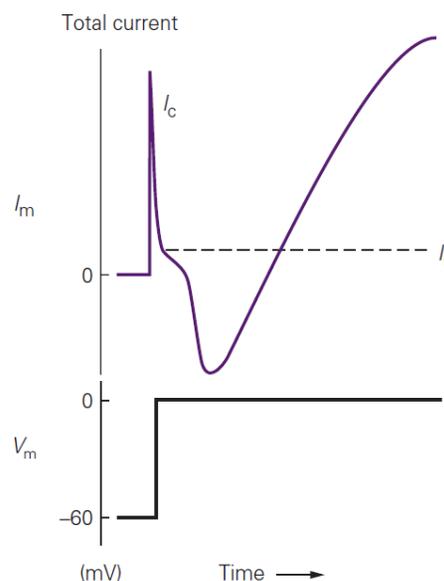


Figura 3.15. Corriente total en respuesta a una gran despolarización [Kandel 2013]

Una despolarización mayor, por ejemplo, de 60 mV , da como resultado corrientes capacitivas y de fuga más grandes, más una corriente iónica entrante seguida de una corriente iónica externa, ambas dependientes del tiempo (Figura 3.15).

Hodgkin y Huxley interpretaron que esta despolarización abre secuencialmente dos tipos de canales activados por voltaje y que involucran dos iones distintos (Figura 3.16).

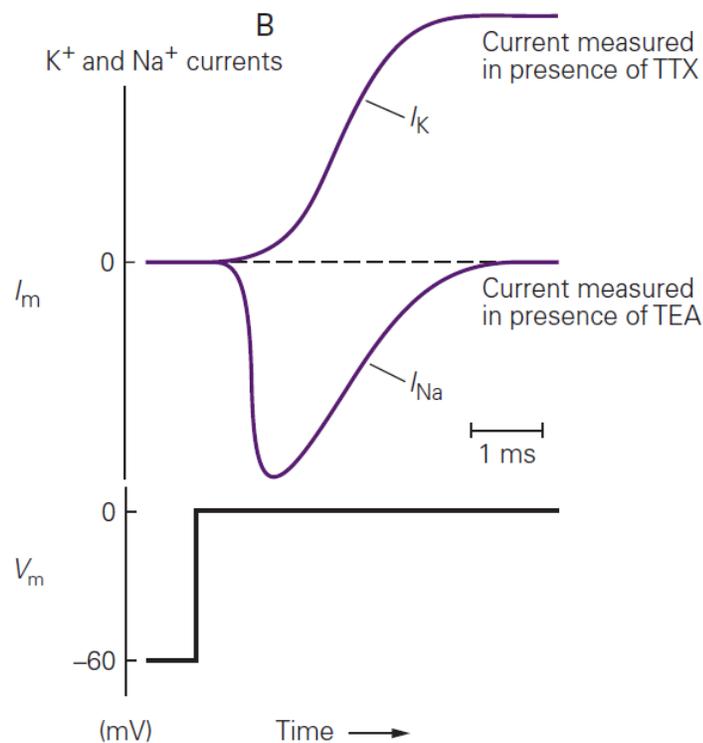


Figura 3.16. Corrientes individuales de sodio I_{Na} y potasio I_K después de restar I_c e I_l obtenidas con la aplicación de la tetrodotoxina (TTX), y el tetraetilamonio (TEA) [Kandel 2013]

Un tipo de canal conduce iones que generan una corriente entrante, mientras que el otro conduce iones que generan una corriente saliente. Estas dos corrientes se solapan parcialmente en el tiempo, por lo tanto, se necesitaba conocer su comportamiento por separado. Para esto, utilizaron drogas o toxinas que bloquean selectivamente las diferentes clases de canales activados por voltaje. Aplicaron tetraetilamonio al axón del calamar, que bloquea los canales de potasio. Observaron que la corriente de membrana total I_m se compone de las corrientes I_c , I_l e I_{Na} y que la

conductancia de fuga, g_l se mantiene constante. De esta manera se podía conocer I_l y restar de I_m , dejando I_{Na} e I_c , esta última ocurre sólo brevemente al comienzo y al final del pulso, y se puede aislar, revelando la corriente de I_{Na} . De la misma manera se puede medir I_K , bloqueando los canales de potasio con tetrodotoxina.

Hodgkin y Huxley aplicaron este procedimiento a un amplio rango de potenciales, y pudieron medir las corrientes de sodio y potasio en toda la extensión de voltaje del potencial de acción (Figura 3.17).

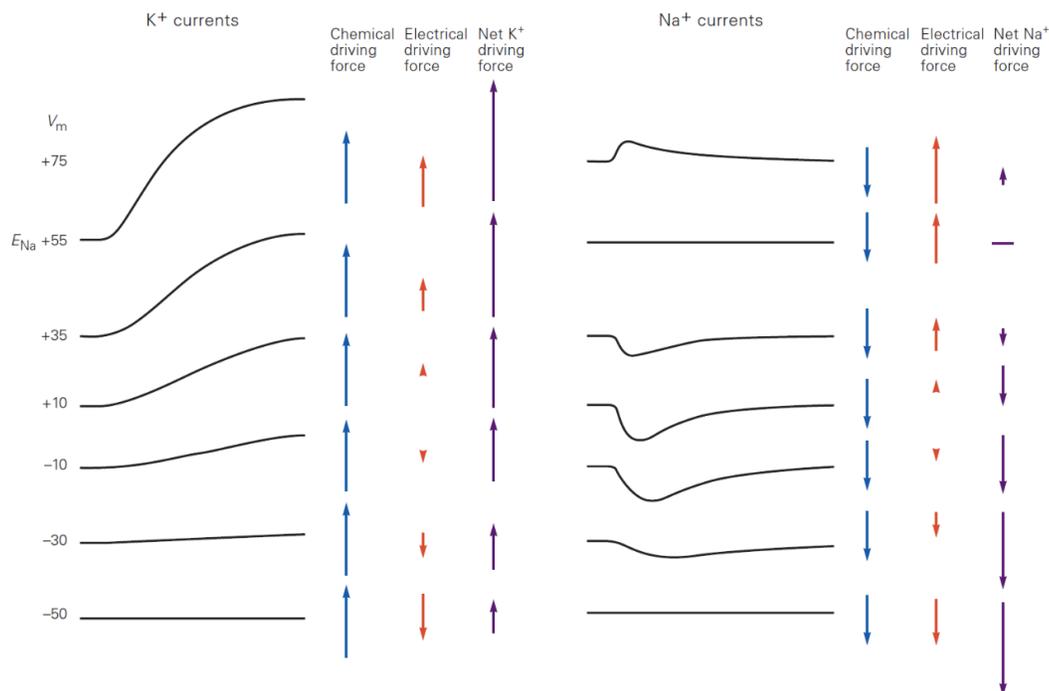


Figura 3.17. Comportamientos individuales de las corrientes de sodio I_{Na} y potasio I_K al aplicar una despolarización progresiva a la membrana mediante la técnica de fijación de voltaje. Se observan los cambios en las fuerzas electroquímicas por separado y la fuerza impulsora neta en cada caso [Kandel 2013]

Concluyeron que las corrientes de sodio y potasio son funciones graduales del potencial de membrana. La corriente saliente del potasio se incrementa a medida que el voltaje de la membrana se vuelve más positivo. Lo mismo ocurre con la corriente entrante del sodio, pero al continuar la despolarización, llega un punto en que disminuye en amplitud, y cuando el potencial de membrana es $+55 \text{ mV}$, la corriente de sodio es cero, invierte su dirección y se vuelve saliente, es decir, la fuerza motriz eléctrica que empuja

al sodio hacia afuera es ahora mayor que la fuerza motriz química que lo empuja hacia adentro y, por lo tanto, la corriente del sodio se vuelve saliente.

Hodgkin y Huxley explicaron este comportamiento mediante un modelo muy simple en el que el tamaño de las corrientes de sodio y potasio está determinado por dos factores: la magnitud de sus conductancias g_{Na} y g_K , que son funciones del número de canales de sodio y potasio abiertos en cualquier instante, y la fuerza motriz electroquímica en los iones de sodio y potasio, es decir (Ecuación 3.4):

$$I_K = g_K (V - E_K) \quad e \quad I_{Na} = g_{Na} (V - E_{Na}) \quad (3.4)$$

Para explicar las Ecuaciones (3.4), se necesita reafirmar las bases eléctricas de la neurona, después de lo cual, se llegará al circuito eléctrico equivalente.

Dada la naturaleza eléctrica de la neurona, el modelo utilizado, llamado circuito eléctrico equivalente, representa todas las propiedades eléctricas importantes de la neurona en base a resistencias, fuentes y condensadores. El primer paso consiste en relacionar las propiedades físicas discretas de la membrana con sus propiedades eléctricas. La bicapa lipídica, denota la *capacitancia* eléctrica de la membrana, que es la capacidad de un material aislante (no conductor) para separar las cargas eléctricas a cada lado (como un capacitor). La presencia de una capa delgada de cargas opuestas en las superficies internas y externas de la membrana neuronal, la convierten en un condensador (capacitor), lo que da lugar a la diferencia de potencial eléctrico a través de la membrana. La diferencia de potencial eléctrica o voltaje a través de un condensador es $V = Q/C$ donde Q es la cantidad de carga positiva o negativa neta en cada lado del condensador de capacitancia C . Las unidades de capacitancia son Faradios (F), y las de carga son Culombios. Como referencia, una separación de carga de 1 Coulomb a través de un condensador de $1 F$ produce una diferencia de potencial de 1 Volt. La capacidad de membrana para una célula nerviosa es aproximadamente $1 \mu F$ por cada cm^2 de área de la membrana.

Se dice que la membrana neuronal es un condensador con *fugas* (*leaky capacitor*) porque está tachonada con canales iónicos donde se puede fugar la carga (ver Figura 3.13).

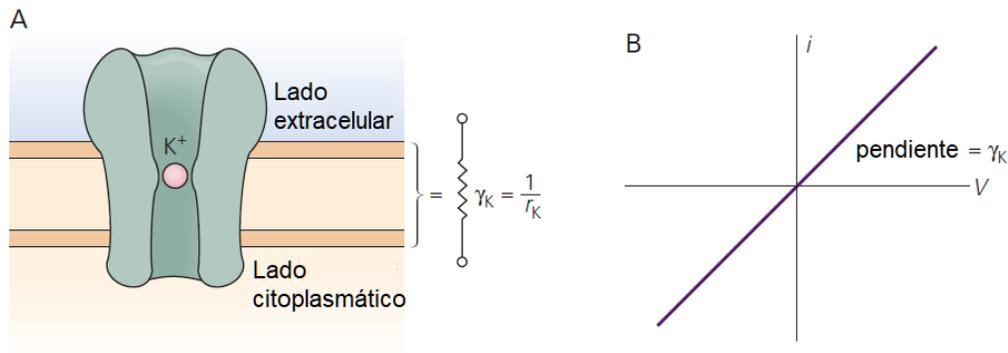


Figura 3.18. Representación eléctrica de un canal iónico. A) Un canal iónico individual (por ejemplo, canal de potasio) puede ser representado por un conductor o por un resistor. B) En ausencia de un gradiente de concentración, la relación de corriente y voltaje de un canal iónico individual sigue la ley de ohm [Kandel, 2013]

Los canales iónicos proporcionan vías de resistencia eléctrica finita para que los iones puedan cruzar la membrana. En un circuito equivalente, se puede representar un sólo canal, por ejemplo, el de K^+ , como una resistencia de corriente iónica o como una conductancia $\gamma_K = 1/\text{Resistencia}$ (Figura 3.18).

Debido a que hay dos tipos de fuerzas que impulsan a los iones a través de la membrana, el flujo de iones está dado por: Flujo iónico = (fuerza electromotriz + fuerza químico-motriz)(conductancia de membrana), y dado que la concentración del ion potasio en el equilibrio es más alta en el medio intracelular, mientras que la concentración de sodio es más alta en el medio extracelular, es de esperarse que la fuerza originada por el gradiente de concentración, impulse al potasio al exterior, creando una corriente iónica hacia afuera de la neurona, y según la convención para la corriente, un movimiento hacia afuera de carga positiva a través de la membrana corresponde a una corriente positiva. De acuerdo con la ecuación de Nernst, cuando la concentración de K^+ dentro de la célula es más alta que afuera, el potencial de equilibrio para ese ion es negativo, por lo que se requiere el signo negativo porque un potencial de equilibrio negativo produce una corriente positiva. Entonces, en ausencia de fuerza electromotriz:

$$i_K = -\gamma_K \cdot E_K \quad (3.5)$$

donde E_K es el potencial de Nernst para el potasio, γ_K es la conductancia de un sólo canal iónico del potasio. En otras palabras, esta situación se puede modelar con un circuito equivalente que consiste en una conductancia en serie con una batería

(acumulador), donde la batería representa la fuerza motriz química, o gradiente de potencial químico que esta dado por el potencial de Nernst E_K (Figura 3.19).

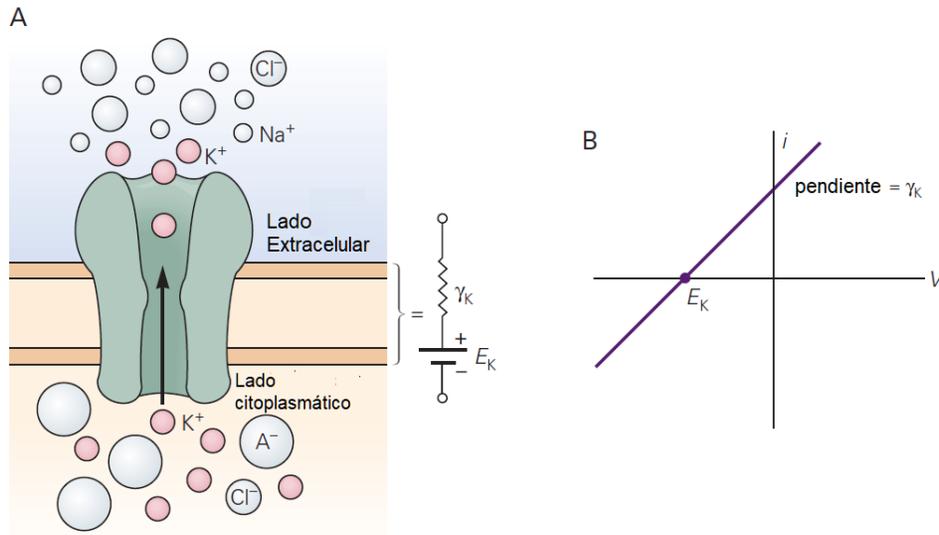


Figura 3.19. Fuerzas eléctricas y químicas que contribuyen al paso de corriente través de un canal iónico [Kandel, 2013]

Finalmente, para una neurona real que tiene un voltaje de membrana y un gradiente de concentración de K^+ , la corriente neta del ion K^+ viene dada por la suma de las corrientes causadas por las fuerzas impulsoras eléctricas y químicas:

$$i_K = \gamma_K (V_m - E_K) \quad (3.6)$$

donde el término $(V_m - E_K)$ es la fuerza motriz electroquímica resultante, y es la que determina la dirección de la corriente iónica. Como la membrana neuronal tiene muchos canales de K^+ en reposo, se pueden representar en un circuito equivalente que consiste en una conductancia total en serie con una batería, y donde la **conductancia total** de todos los canales de potasio, denotados ahora por g_K , es igual al número de canales de K^+ en reposo (N_K), multiplicado por la conductancia de un canal de potasio individual γ_K , es decir:

$$g_K = N_K \cdot \gamma_K \quad (3.7)$$

Así mismo, el gradiente de concentración del K^+ es independiente del número de canales de potasio, y como antes, su valor es el potencial de equilibrio E_K . Si se denota con I_K la corriente iónica total a través de todos los canales de potasio K^+ , y se denota el potencial

de membrana (V_m) simplemente como V , entonces la corriente total a través de todos los canales de potasio K^+ viene dada como: $I_K = g_K (V - E_K)$.

El mismo análisis se les aplica a los canales iónicos restantes de Na^+ , Ca^{2+} y Cl^- , que representan la mayor parte de la corriente iónica pasiva a través de la membrana celular en reposo. De esta manera, las corrientes totales iónicas a través de todos los canales de K^+ , Na^+ , Ca^{2+} y Cl^- , están dadas por (3.8), que, como antes, E_{Na} , E_{Ca} y E_{Cl} son los potenciales de reposo, o potenciales de Nernst para los iones de Na^+ , Ca^{2+} y Cl^- respectivamente.

$$\left. \begin{aligned} I_K &= g_K (V - E_K) & I_{Na} &= g_{Na} (V - E_{Na}) \\ I_{Ca} &= g_{Ca} (V - E_{Ca}) & I_{Cl} &= g_{Cl} (V - E_{Cl}) \end{aligned} \right\} \quad (3.8)$$

Las unidades de corriente iónica son $\mu A/cm^2$ y las unidades de conductancia son mS/cm^2 ($S = Siemens = \Omega^{-1} = Ampers (A)/Volts (V)$).

Las ecuaciones (3.8) explican el origen de las ecuaciones (3.4). Ahora se tienen elementos para construir el circuito eléctrico equivalente que sirve como base del modelo matemático del funcionamiento de la neurona, para lo cual, sólo se necesita conectar los elementos que representan cada tipo de canal en sus dos extremos con elementos que representan el líquido extracelular y el citoplasma (Figura 3.20).

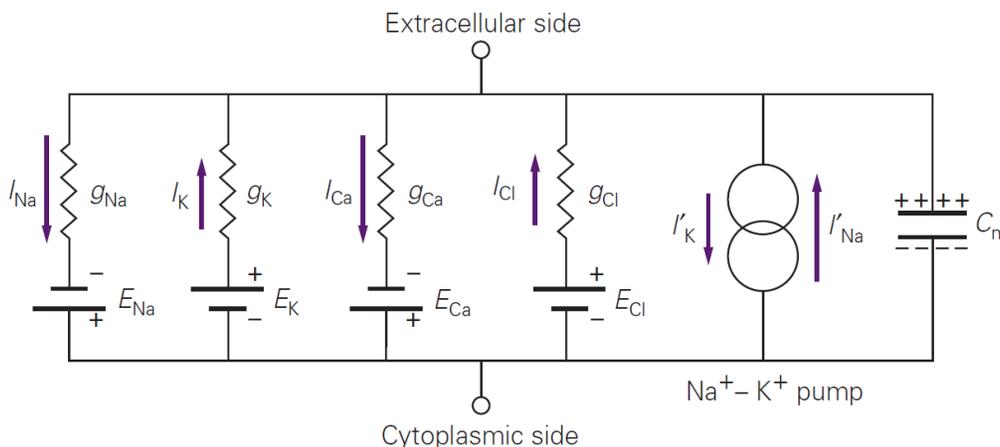


Figura 3.20. Circuito eléctrico equivalente base del modelo matemático de la neurona. Incluye cuatro tipos de corrientes iónicas y bombas de $Na^+ - K^+$ [Kandel 2013]

Para ser más realista, el circuito contempla cuatro tipos de corrientes iónicas que normalmente se encuentran en neuronas del cerebro humano, e incorpora los flujos de iones activos impulsados por la bomba $Na^+ - K^+$, que controla las concentraciones

intracelulares de iones de sodio y potasio, moviéndolos contra sus gradientes electroquímicos, forzando la salida de tres iones de sodio por cada dos iones potasio que absorbe. Estas bombas electrogénicas que mantiene las baterías iónicas cargadas se pueden agregar al circuito equivalente en forma de un generador de corriente.

En el estudio del axón gigante del calamar, Hodgkin y Huxley encontraron una predominancia de iones de sodio y potasio. Las otras especies iónicas como el Cl^- , se encuentran en menor cantidad, es por esto por lo que, para facilitar su estudio y tener un modelo más simplista, el resto de las especies iónicas se englobaron en las corrientes de fuga lo mismo que las bombas de sodio-potasio por tener corrientes iónicas muy bajas.

En la Figura 3.21 se muestra el circuito equivalente resultante de estas simplificaciones y se agrega la configuración de la técnica de fijación de voltaje (voltage-clamp). De esta manera, las ecuaciones (3.8), se reducen a las ecuaciones (3.4): $I_K = g_K (V - E_K)$, $I_{Na} = g_{Na} (V - E_{Na})$, que habían quedado pendientes de explicar, y que ahora se retoma la explicación dada antes de la interrupción necesaria para explicar las bases eléctricas de la neurona, es decir, de su membrana plasmática.

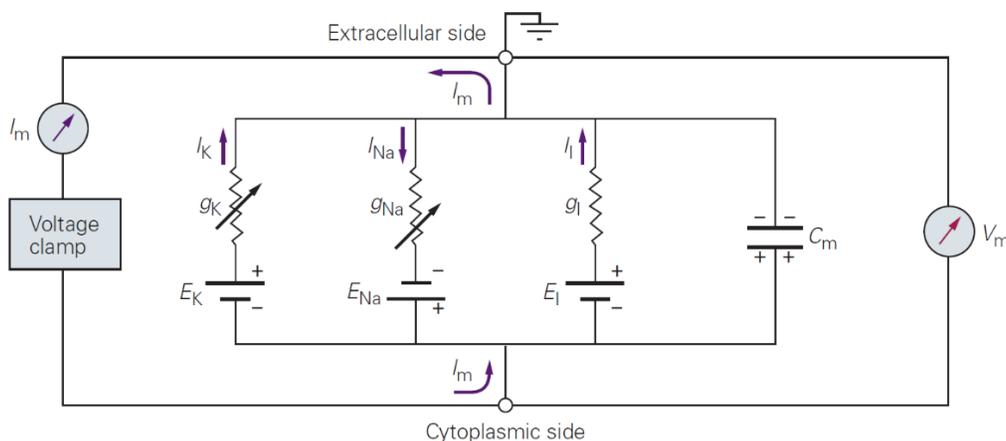


Figura 3.21. Circuito eléctrico equivalente simplificado que incluye la configuración a voltaje fijo (voltage-clamp) utilizado por Hodgkin y Huxley en su investigación [Kandel, 2013]

Despejando de las ecuaciones (3.4), Hodgkin y Huxley pudieron calcular las conductancias de sodio y potasio. De igual manera que para las corrientes iónicas, mediante la técnica de fijación de voltaje, se midieron las conductancias de sodio y potasio para varios niveles de potencial de membrana, lo que reveló que ambos tipos de

canales se abren en respuesta a la despolarización y que la probabilidad y tasa de apertura para ambos tipos de canales, aumentan al aumentar la despolarización. En todos los niveles de despolarización, los canales de sodio se abren más rápidamente que los de potasio, y si la despolarización se prolonga, los canales de sodio comienzan a cerrarse, disminuyendo la corriente entrante, y no se abren hasta que la membrana se repolariza nuevamente, lo que la reinicia a sus condiciones originales. Esto llevó a la observación de que la despolarización induce en los canales de sodio tres estados diferentes: reposo, activados o inactivados (Figura 3.22). No así los canales de potasio del axón del calamar (con cuatro estados) que permanecen abiertos (activados) durante la despolarización (Figura 3.23). Cada canal de sodio tiene una puerta de activación que se cierra mientras la membrana está en el potencial de reposo y se abre por despolarización. Esto crea los efectos variables y dependientes del tiempo en las conductancias del sodio (y potasio) durante la despolarización (Figura 3.23). Esta variabilidad se representa por las flechas sobre las conductancias en el circuito equivalente.

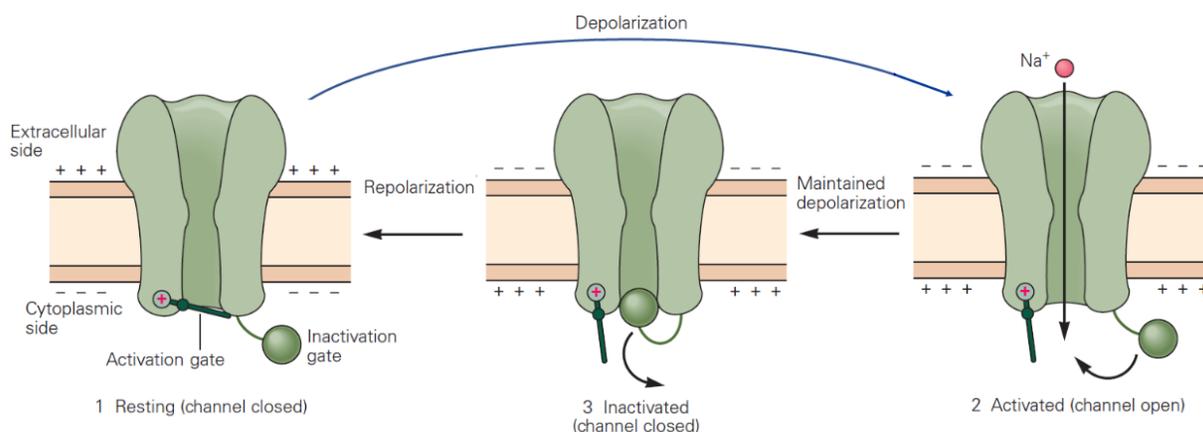


Figura 3.22. La despolarización induce en los canales de sodio tres estados diferentes: reposo, activados o inactivados [Kandel, 2013]

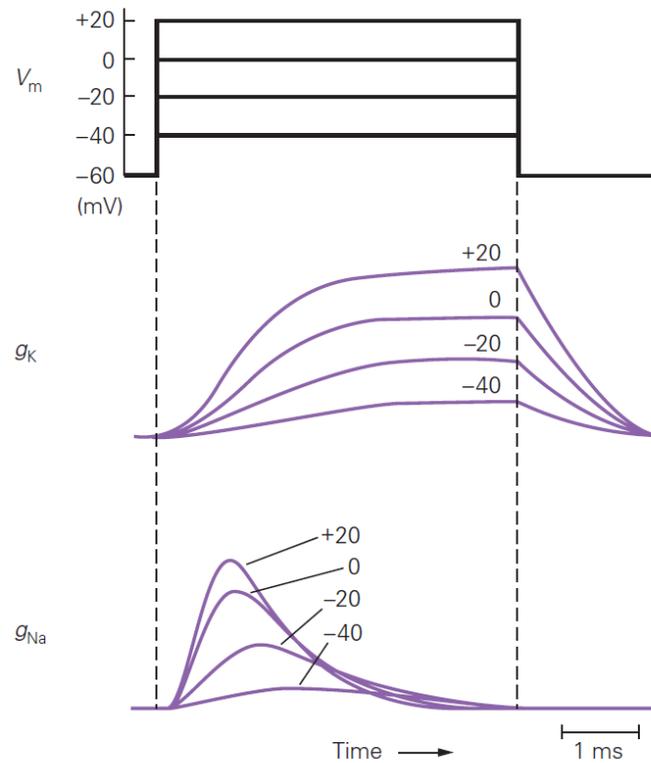


Figura 3.23. Respuesta de los canales de Na^+ y K^+ a una despolarización prolongada [Kandel. 2013]

Después de esta explicación detallada sobre la naturaleza eléctrica de la neurona, se está preparado para llegar al modelo matemático del funcionamiento de la membrana plasmática, o dicho de una manera más general, del proceso de señalización eléctrica de la neurona, que explica las bases moleculares del potencial de acción.

Para efectos de generalidad, se puede partir de un circuito como el de la Figura 3.24, que contempla cuatro especies iónicas, pero sin tomar en cuenta las bombas de sodio-potasio, para después volver a un circuito parecido al de la figura 3.21, sólo con dos especies iónicas: sodio y potasio.

En el circuito mostrado en la Figura 3.24, según Kirchoff, la corriente total I que cruza del lado plasmático al lado extracelular es la suma de corrientes iónicas $I_K, I_{Na}, I_{Ca}, I_{Cl}$ más la corriente capacitiva I_C , (las corrientes que entran al circuito es igual a las corrientes que salen de él) es decir:

$$I = I_C + I_K + I_{Na} + I_{Ca} + I_{Cl} \quad (3.9)$$

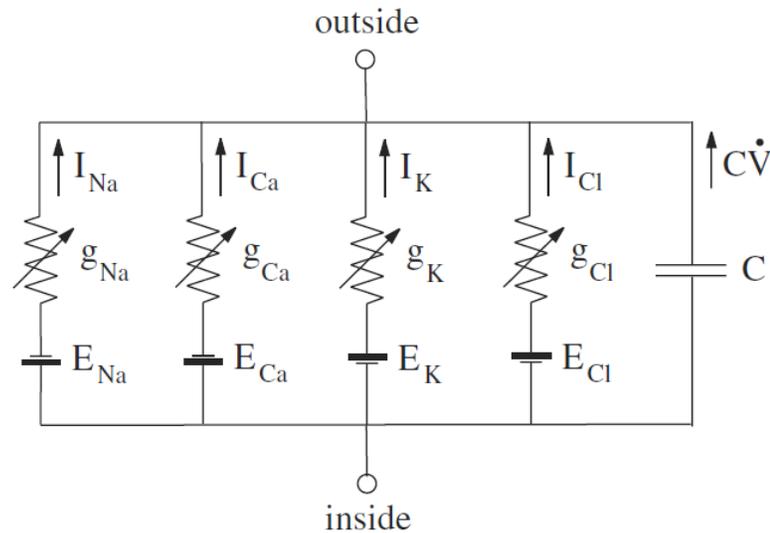


Figura 3.24. Circuito eléctrico general equivalente base del modelo matemático de la neurona. Incluye cuatro tipos de corrientes iónicas [Izhikevich, 2007]

Nótese que, aunque en la figura se tomaron las corrientes salientes, I_K es una corriente iónica saliente, al igual que I_{Cl} que, aunque es entrante, al estar cargada negativamente, tiene el efecto de corriente saliente, por lo tanto: I_K, I_{Cl} son corrientes iónicas salientes, mientras que I_{Na}, I_{Ca} son corrientes iónicas entrantes. Al final las direcciones de las corrientes tienen que concordar con esto último (ver Figura 3.20).

Respecto a la corriente capacitiva, se mencionó más arriba que $V = Q/C$, o también, $Q = CV$ derivando respecto al tiempo: $\frac{dQ}{dt} = C \frac{dV}{dt}$ donde $\frac{dQ}{dt} = I_c$ y $\frac{dV}{dt} = \dot{V}$, entonces, $I_c = C\dot{V}$. Sustituyendo en la ecuación (3.9) y espejando el termino $C\dot{V}$, se obtiene:

$$C\dot{V} = I - I_K - I_{Na} - I_{Ca} - I_{Cl} \quad (3.10)$$

En el lenguaje matemático esta ecuación diferencial es un *sistema dinámico*. Sustituyendo las ecuaciones (3.8) en (3.10) se obtiene:

$$C\dot{V} = I - g_K(V - E_K) - g_{Na}(V - E_{Na}) - g_{Ca}(V - E_{Ca}) - g_{Cl}(V - E_{Cl}) \quad (3.11)$$

Un **resultado particular** se obtiene, suponiendo que si las corrientes iónicas $I_K, I_{Na}, I_{Ca}, I_{Cl}$ son las únicas que atraviesan la membrana, entonces $I = 0$, además, en reposo, el potencial de membrana se supone constante, por lo que $\dot{V} = 0$. Sustituyendo

estos valores en la ecuación (3.11), realizando las multiplicaciones expresadas y reagrupando, se obtiene V_r como centro de masa de los potenciales involucrados:

$$V_r = \frac{g_K E_K + g_{Na} E_{Na} + g_{Ca} E_{Ca} + g_{Cl} E_{Cl}}{g_K + g_{Na} + g_{Ca} + g_{Cl}} \quad (3.12)$$

Este último resultado nos lleva a simplificar el circuito eléctrico en otro equivalente donde $g_{inp} = g_K + g_{Na} + g_{Ca} + g_{Cl}$ es una conductancia global. Ver Figura 3.25.

Según este circuito, la corriente que cruza esta rama es $I_r = g_{inp}(V - V_r)$ con lo cual podemos escribir la ecuación (3.11) como:

$$C\dot{V} = I - g_{inp}(V - V_r) \quad (3.13)$$

Se dice que la resistencia de entrada o resistencia global $R_{inp} = 1/g_{inp}$ mide la *sensibilidad asintótica* de la membrana a corrientes intrínsecas o inyectadas. Sustituyendo R_{inp} en la ecuación (3.13), para un voltaje fijo, $V \rightarrow V_r + IR_{inp}$. Tanto R_{inp} como g_{inp} son funciones del tiempo y de V , porque se requiere tiempo para depositar o remover carga de la membrana (capacitancia), cambiando también V .

Retomando la ecuación (3.11), cada término de la forma: $g_i(V - E_i)$ debe de tomar en cuenta que hay grandes poblaciones de canales idénticos, y también la probabilidad de apertura y cierre, debido esto último a su naturaleza estocástica. Por lo tanto, dichos términos deben sustituirse por términos de la forma:

$$I_i = \bar{g}_i p (V - E_i) \quad (3.14)$$

donde p es la proporción promedio de canales en estado abierto, \bar{g}_i es la conductancia máxima de la población, y E_i es el potencial en el que la corriente invierte su dirección.

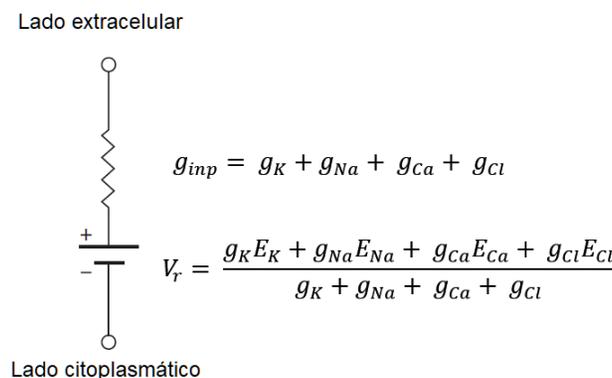


Figura 3.25. Circuito eléctrico equivalente [Izhikevich, 2007]

La probabilidad de que, en un tipo de canal iónico, una compuerta de inactivación esté en estado abierto se indica mediante la variable h . La proporción de canales abiertos en una gran población es:

$$p = m^a h^b \quad (3.15)$$

donde a es el número de compuertas de activación, y b es el número de compuertas de inactivación por canal. Los canales pueden estar parcialmente activados: $0 < m < 1$; completamente activados: $m = 1$; no activados (desactivados): $m = 0$; inactivado: $h = 0$; liberado de la inactivación o desactivado: $h = 1$.

Algunos canales no tienen compuertas de inactivación, por lo tanto, $b = 0$, y $p = m^a$. Dichos canales no se desactivan y dan como resultado, corrientes persistentes. En contraste, los canales que se desactivan dan como resultado, corrientes transitorias.

La variable de activación m en la ecuación $p = m^a$, esta dada por la ecuación diferencial:

$$\dot{m} = (m_\infty(V) - m)/\tau(V) \quad (3.16)$$

donde $m_\infty(V)$ es la función de activación de estado estable, sensible al voltaje, que proporciona el valor asintótico de m cuando el potencial es fijo (fijación de voltaje), y al igual que la constante de tiempo $\tau(V)$ pueden medirse experimentalmente (Figura 3.26).

La variable de inactivación h en la ecuación $p = m^a h^b$ esta dada por la ecuación diferencial:

$$\dot{h} = (h_\infty(V) - h)/\tau(V) \quad (3.17)$$

donde $h_\infty(V)$ es la función de inactivación de estado estable, sensible al voltaje (Figura 3.26).

En el modelo del axón gigante de calamar, Hodgkin y Huxley determinaron que en el axón hay tres corrientes principales: 1) Corriente persistente de potasio activada por voltaje con cuatro puertas de activación, que da como resultado un término n^4 en la ecuación $p = m^a h^b$, con $m = n$ y $b = 0$, donde n es la activación variable para el potasio (K^+). 2) Corriente de voltaje transitoria de sodio (Na^+), con tres compuertas de activación y una compuerta de inactivación $p = m^3 h$, donde m es la variable para el sodio con $a = 3$ y $b = 1$ en la ecuación $p = m^a h^b$. 3) Corriente de fuga I_l , que es transportada principalmente por iones de cloro Cl^- .

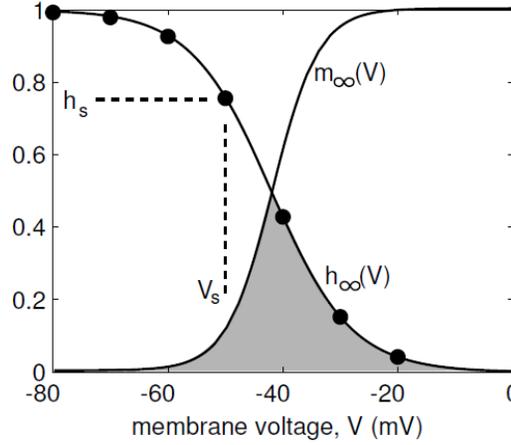


Figura 3.26. Representación de las Función $m_{\infty}(V)$ y $h_{\infty}(V)$. La región sombreada representa una corriente notable y persistente [Izhikevich, 2007].

Considerando lo expuesto, **el conjunto de ecuaciones de Hodgkin-Huxley completo** en el espacio a voltaje fijo (voltage-clamp) es:

$$C\dot{V} = I - \bar{g}_K n^4 (V - E_K) - \bar{g}_{Na} m^3 h (V - E_{Na}) - g_l (V - E_l) \quad (3.18)$$

$$\left. \begin{aligned} \dot{n} &= \alpha_n(V)(1-n) - \beta_n(V)(n) \\ \dot{m} &= \alpha_m(V)(1-m) - \beta_m(V)(m) \\ \dot{h} &= \alpha_h(V)(1-h) - \beta_h(V)(h) \end{aligned} \right\} \quad (3.18a)$$

donde

$$I_K = \bar{g}_K n^4 (V - E_K), \quad I_{Na} = \bar{g}_{Na} m^3 h (V - E_{Na}) \quad e \quad I_l = g_l (V - E_l)$$

con

$$\alpha_n(V) = 0.01 \frac{10 - V}{\exp\left(\frac{10-V}{10}\right) - 1} \quad \beta_n(V) = 0.125 \exp\left(\frac{-V}{80}\right) \quad (3.19a)$$

$$\alpha_m(V) = 0.1 \frac{25 - V}{\exp\left(\frac{25-V}{10}\right) - 1} \quad \beta_m(V) = 4 \exp\left(\frac{-V}{18}\right) \quad (3.19b)$$

$$\alpha_h(V) = 0.07 \exp\left(\frac{-V}{20}\right) \quad \beta_h(V) = \frac{1}{\exp\left(\frac{30-V}{10}\right) + 1} \quad (3.19c)$$

Los parámetros $\alpha_i(V), \beta_i(V)$ anteriores, son proporcionados en el documento original de Hodgkin y Huxley, y corresponden al potencial de membrana desplazado en

aproximadamente 65 mV , de modo que el potencial de reposo está en $V \approx 0$. Los potenciales de equilibrio de Nernst desplazados son:

$$E_K = -12 \text{ mV}, \quad E_{Na} = 120 \text{ mV}, \quad E_l = 10.6 \text{ mV};$$

Los valores típicos de las conductancias máximas son

$$\bar{g}_K = 36 \text{ mS} / \text{cm}^2, \quad \bar{g}_{Na} = 120 \text{ mS} / \text{cm}^2, \quad g_L = 0.3 \text{ mS} / \text{cm}^2$$

La capacitancia de la membrana es $C = 1 \mu\text{F} / \text{cm}^2$ y la corriente aplicada es, $I = 0 \mu\text{A} / \text{cm}^2$.

Las funciones $\alpha_i(V), \beta_i(V)$ son una notación que tiene razones históricas, y describen las tasas de transición entre los estados abierto y cerrado de los canales.

La forma estándar utilizada en estudios modernos del modelo matemático de la membrana neuronal se da como (3.20a) y (3.20b).

$$\left. \begin{aligned} \dot{n} &= (n_\infty(V) - n) / \tau_n(V) \\ \dot{m} &= (m_\infty(V) - m) / \tau_m(V) \\ \dot{h} &= (h_\infty(V) - h) / \tau_h(V) \end{aligned} \right\} \quad (3.20a)$$

donde (**Figura 3.27**):

$$\left. \begin{aligned} n_\infty &= \alpha_n / (\alpha_n + \beta_n), & \tau_n &= 1 / (\alpha_n + \beta_n) \\ m_\infty &= \alpha_m / (\alpha_m + \beta_m), & \tau_m &= 1 / (\alpha_m + \beta_m) \\ h_\infty &= \alpha_h / (\alpha_h + \beta_h), & \tau_h &= 1 / (\alpha_h + \beta_h) \end{aligned} \right\} \quad (3.20b)$$

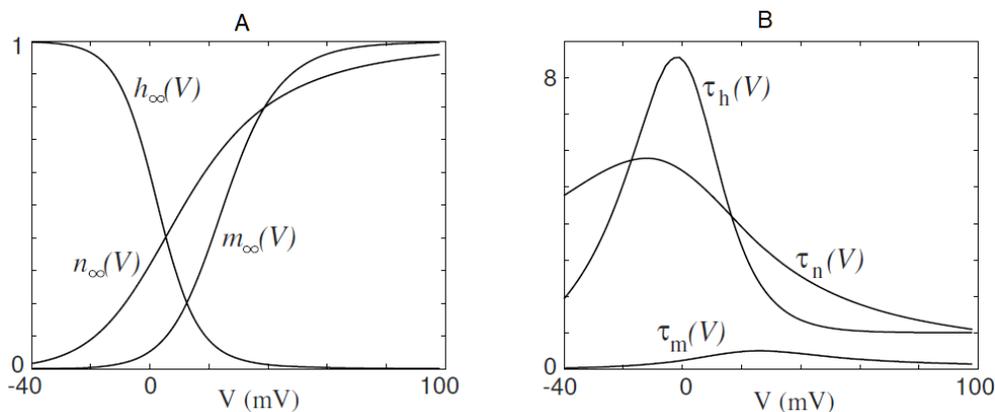


Figura 3.27: Comportamiento de: A) Funciones de activación e inactivación de estado estable. B) Constantes de tiempo dependientes de voltaje en el modelo Hodgkin-Huxley [Izhikevich, 2007]

Se puede apreciar en la Figura 3.28 el comportamiento típico respecto al tiempo de un potencial de acción en el sistema Hodgkin-Huxley. Una fuerte despolarización

produce un aumento en las variables de activación m_∞ y n_∞ y una disminución en la variable de inactivación h_∞ (Figura 3.27A). Debido a que τ_m es relativamente pequeño (Figura 3.27B), la variable m_∞ es relativamente rápida (Ecuación 3.20).

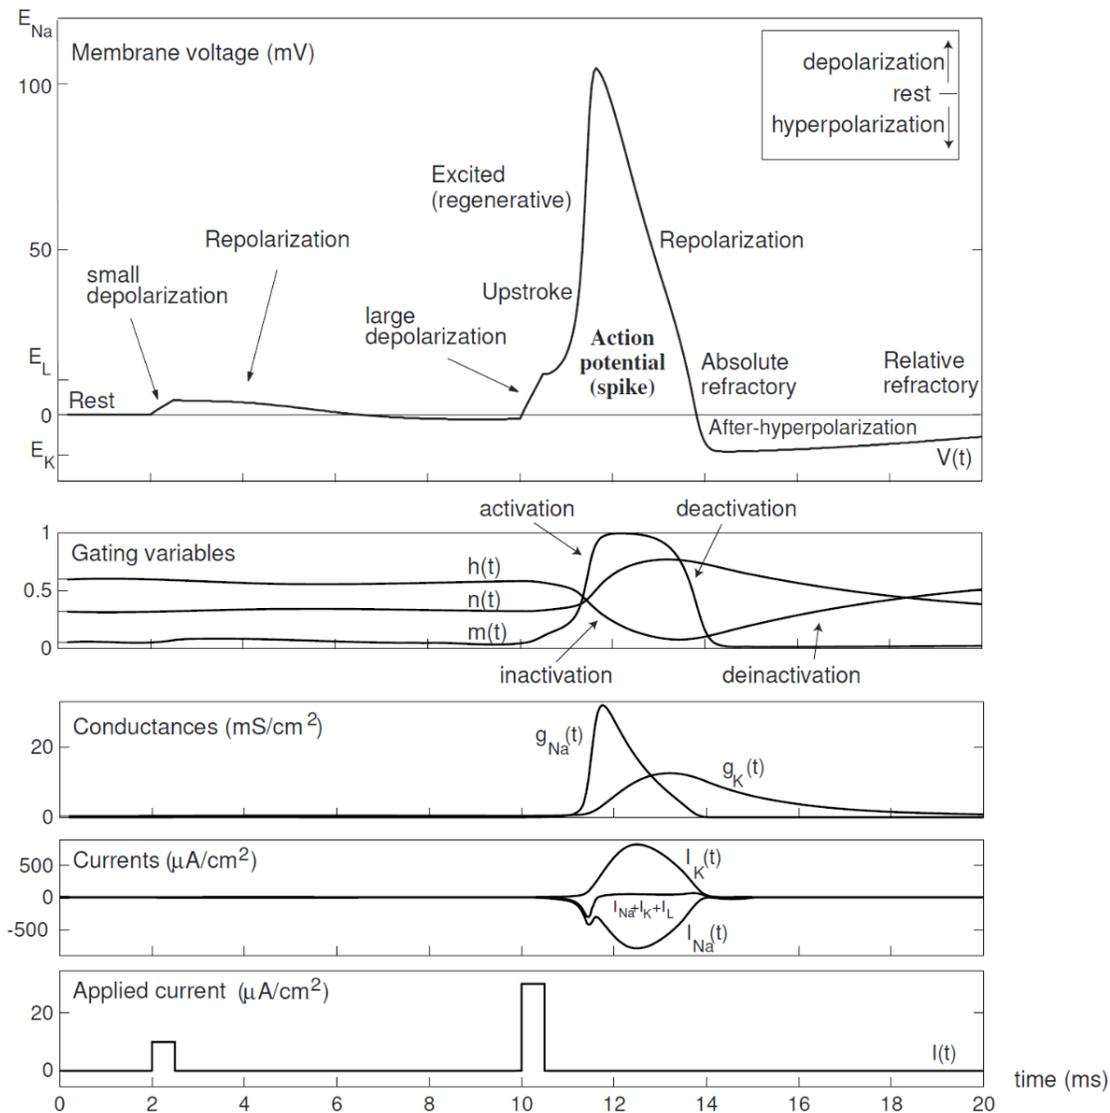


Figura 3.28. Potencial de acción en el modelo Hodgkin-Huxley [Izhikevich, 2007]

El aumento en la conductancia del sodio Na^+ lleva al potencial de membrana V al potencial de equilibrio del sodio E_{Na} , aumentando aún más la despolarización y reactivando la conductancia del sodio g_{Na} , lo que crea un ciclo de retroalimentación positiva (Figura 3.29), resultando en un proceso ascendente del potencial de membrana V . En tanto V se esté aproximando cada vez más a E_{Na} , la variable $h \rightarrow 0$, que inactiva la corriente de sodio. También $n \rightarrow 1$, que induce la activación lenta de la corriente de

potasio hacia el exterior. Esto junto con la corriente de fuga provocan una repolarización lo que lleva al potencial de membrana hacia el potencial de reposo, o equilibrio V_r . Cuando $V \rightarrow V_r$, se observa que τ_n y τ_h tienen valores altos relativamente (Figura 3.27). Por lo tanto, la recuperación de las variables n y h es lenta (Ecuación 3.20a).

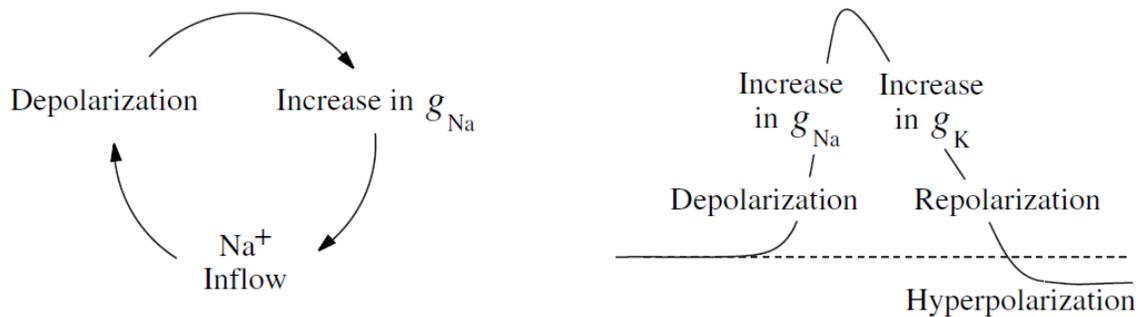


Figura 3.29: Ciclo de retroalimentación positiva y negativa que resultan en un comportamiento regenerativo en las neuronas [Izhikevich, 2007]

Cuando n es grande la corriente iónica de potasio saliente continúa aumentando incluso después de la parte descendente del potencial de acción, lo que provoca que el potencial de membrana V , descienda por debajo del potencial de membrana V_r , acercándose a E_K . Como h es pequeña, la corriente de sodio continúa inactivada, a lo que se llama periodo refractario, y no se puede generar otro potencial de acción durante este periodo refractario absoluto, hasta que la membrana se encuentre por lo menos en un estado de polarización llamado periodo refractario relativo.

El modelo Hodgkin-Huxley se erige como el modelo cuantitativo más exitoso en la ciencia neuronal, sino es que en toda la biología.

Referencias de esta sección: [Kandel, 2013] [Bear, 2016] [Dayan-Abbott, 2001] [Gerstner-Kistler, 2014] [Izhikevich, 2007] [Hodkin-Huxley, 1952] [Arbib, 2002].

3.9. Modelo matemático neuronal de McCulloch-Pitts

El modelo neuronal de McCulloch y Pitts es considerado como la primera teoría a la cual se le suele atribuir el empleo *práctico* de la lógica y la noción matemática de computación, para tratar de explicar funciones mentales en términos de mecanismos neuronales. Se dice que con su trabajo nació la era moderna de las Redes Neuronales Artificiales y aún más, el nacimiento de la Inteligencia Artificial. Por esta razón, el artículo original de McCulloch y Pitts, “A Logical Calculus of the Ideas Immanent in Nervous Activity”, se cita con frecuencia como punto de partida en estudios en Redes Neuronales Artificiales.

Al revisar las contribuciones de McCulloch y Pitts en bibliografía sobre Redes Neuronales Artificiales, su modelo neuronal se describe como modelo de lógica de umbral, que utiliza señales binarias (unos y ceros) únicamente. Las redes están compuestas de entradas o conexiones dirigidas no ponderadas de tipo excitatorio o inhibitorio, y un cierto valor de umbral θ . Se dice que el modelo de McCulloch-Pitts contiene todas las características necesarias para la aplicación de los modelos más complejos.

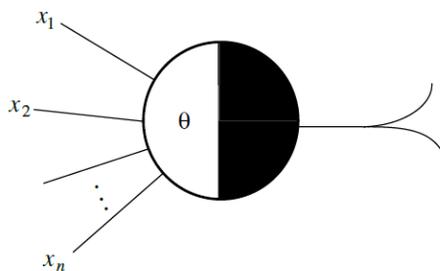


Figura 3.30. Esquema de la neurona de McCulloch y Pitts [Rojas, 2001]

La Figura 3.30 muestra una neurona de McCulloch-Pitts esquematizada según Marvin L. Minsky, que extendió los resultados de McCulloch y Pitts y los puso en el contexto de la teoría de autómatas y la teoría de la computación, estudiados previamente por S. Kleene. Si una unidad de McCulloch-Pitts recibe dos tipos de entradas x_i y y_j con $i = 1, 2, \dots, n$ y $j = 1, 2, \dots, m$ a través de n conexiones excitatorias y m conexiones inhibitorias respectivamente, si $m \geq 1$, y al menos una y_j esta activada, da como

resultado la inhibición de la neurona, de lo contrario, la excitación total se calcula mediante $\sum_{i=1}^n x_i$, y si $\sum_{i=1}^n x_i \geq \theta$ la neurona se dispara a 1, de otra manera no se dispara dando un resultado de 0 (lo mismo ocurre si $n = 0$). Por eso se dice que la *función de activación* de la neurona de McCulloch y Pitts, es la llamada *función escalón*. Debido a lo anterior, la neurona de McCulloch-Pitts puede ser inactivada por una única señal inhibidora, como algunas neuronas reales. Cuando no hay señales inhibitorias presentes, las unidades actúan como una compuerta de umbral capaz de implementar muchas otras funciones lógicas de n argumentos.

En el artículo original de McCulloch y Pitts, para desarrollar su teoría, utilizaron el formalismo de R. Carnap que es muy difícil de seguir, porque no es muy común, además, según S.C. Kleene, es engorroso y obscuro, por esta razón, Kleene, para entender la teoría de McCulloch y Pitts tomó sus ideas, pero realizó su propio estudio, que lo llevo al nacimiento de otro formalismo más general llamado "Autómatas Finitos", y demostró que las redes McCulloch-Pitts son computacionalmente equivalentes a los Autómatas Finitos.

El trabajo de McCulloch y Pitts se fundamenta en la naturaleza de "todo o nada" de los impulsos de las neuronas biológicas, evento que en su trabajo lo relacionan en una correspondencia uno a uno con "átomos mentales" llamados "psychons" (hechos que Kleene desechó), y también en el carácter excitatorio e inhibitorio de las neuronas biológicas. La ley de todo o nada es la base que permitió que McCulloch y Pitts hicieran uso de la lógica para describir la actividad neuronal, en términos de relaciones inferenciales entre proposiciones. Definieron toda una gramática basada en diez teoremas para representar sus expresiones, donde los pulsos neuronales se interpretaban como proposiciones o ideas, entonces las expresiones que describen el comportamiento neuronal podrían verse como una relación lógica entre las entradas de una neurona y sus salidas.

Su teoría [McCulloch-Pitts, 1943] [Piccinini, 2004], se dividió en dos partes: 1) Redes sin "círculos" (ciclos cerrados de actividad), y 2) Redes con círculos (hoy llamadas redes recurrentes), y se sustentó en los siguientes supuestos:

1. La actividad de la neurona es un proceso de "todo o nada".

2. Un cierto número fijo de sinapsis debe excitarse dentro del período de adición latente para excitar una neurona en cualquier momento, y este número es independiente de la actividad previa y la posición de la neurona.
3. El único retraso significativo dentro del sistema nervioso es el retraso sináptico.
4. La actividad de cualquier sinapsis inhibitoria impide absolutamente la excitación de la neurona en ese momento.
5. La estructura de la red no cambia con el tiempo.

Una red neuronal de McCulloch y Pitts, representada por $N_i(t)$ se forma de un conjunto de n neuronas de la forma c_i que se disparan en el tiempo t . Las expresiones de la forma $N_i(t)$ se pueden combinar por medio de conexiones lógicas para formar expresiones complejas que describen el comportamiento de diferentes neuronas en determinado tiempo, por ejemplo, $N_1(t) \wedge N_2(t)$ significa que las neuronas c_1 y c_2 se disparan en el tiempo t . $N_1(t-1) \vee N_2(t-2)$ significa que c_1 se dispara en el tiempo $t-1$, o c_2 se dispara en el tiempo $t-2$, o ambos, y así sucesivamente. Estas expresiones a su vez se pueden combinar con los mismos conectivos lógicos. McCulloch y Pitts permitieron sólo el uso de conjunción ($A \wedge B$), disyunción ($A \vee B$), conjunción y negación ($A \wedge \sim B$), y una conectiva especial S llamado *predecesor temporal* que desplaza el índice temporal de una expresión hacia atrás en el tiempo, de manera que, $S[N_i(t)] = N_i(t-1)$. Expresiones complejas formadas a partir de varias expresiones primitivas $N_i(t)$ por medio de las conectivas utilizadas, se denota por $Expression_j[N_1(t), N_2(t) \dots, N_n(t)]$. En una red sin círculos, las neuronas que no reciben entradas de otras neuronas, se llaman neuronas *aferentes*.

Los dos problemas técnicos principales que McCulloch y Pitts se formularon y resolvieron fueron:

- 1) Dada una red, encontrar una clase de expresiones \mathcal{C} tal que para cada neurona c_i , en \mathcal{C} haya una expresión verdadera de la forma:

$$N_i(t) \text{ si y solo si } Expression_j[N_{i-g}(t-1) \dots, N_{i-2}(t-1), N_{i-1}(t-1)] \quad (3.21)$$

donde las neuronas $c_{i-g} \dots, c_{i-2}, c_{i-1}$ tienen axones que ingresan a c_i .

Esta expresión describe el *comportamiento* de cualquier neurona (no aferente) en términos del comportamiento de las neuronas que son aferente a ella. Si se encuentra

una clase C de tales expresiones, entonces la lógica proposicional puede describir el comportamiento de cualquier neurona no aferente en la red en términos del comportamiento de las neuronas aferentes a ella.

2) Dada una expresión de la forma (3.21) encontrar una red para la cual sea cierto. En otras palabras, los dos problemas se reducen a: 1) Calcular el comportamiento de cualquier red, y 2) Encontrar una red que se comportará de una manera específica, si existe esa red.

McCulloch y Pitts resolvieron el primer problema mostrando la forma de escribir una expresión que describiera la relación entre el disparo de cualquier neurona en una red y las entradas que recibió de sus neuronas aferentes. En el segundo problema mostraron cómo construir redes que satisficieran sus cuatro esquemas combinatorios: conjunción, disyunción, conjunción-negación y predecesor temporal, dando diagramas que muestran las conexiones entre las neuronas que satisfacen cada esquema. Posteriormente, mediante inducción sobre el tamaño de las redes, todas las expresiones formadas por esos esquemas combinatorios son satisfechas por las redes de McCulloch-Pitts. La Figura 3.31 muestra los diagramas de redes McCulloch y Pitts, en la que, para enviar un pulso de salida, cada neurona debe recibir dos entradas excitadoras y ninguna entrada inhibitoria. Las líneas que terminan en un punto representan conexiones excitatorias. Las líneas que terminan en un aro representan conexiones inhibitorias. El objetivo de McCulloch y Pitts era explicar los fenómenos mentales, y para ejemplificarlo, en su mismo artículo presentaron una explicación de la ilusión de calor que es un hecho conocido: Cuando un objeto frío que toca la piel normalmente produce una sensación de frío, pero si se mantiene por un tiempo muy breve y luego se retira, puede causar una sensación de calor.

Partieron del hecho fisiológico conocido de que existen diferentes tipos de receptores afectados por el calor y el frío, y asumieron que hay neuronas cuya actividad implica una sensación de calor, y asignaron una neurona a cada función: 1) Recepción de calor, 2) Recepción de frío, 3) Sensación de calor y 4) Sensación de frío. Observaron que las relaciones entre las neuronas de sensación de calor, ya sea en respuesta al receptor de calor o a una breve actividad del receptor de frío, correspondía a la ilusión de calor, poniendo en claro con este ejemplo, la dependencia de la correspondencia

entre la percepción y el mundo externo sobre las propiedades estructurales específicas de la red nerviosa que interviene.

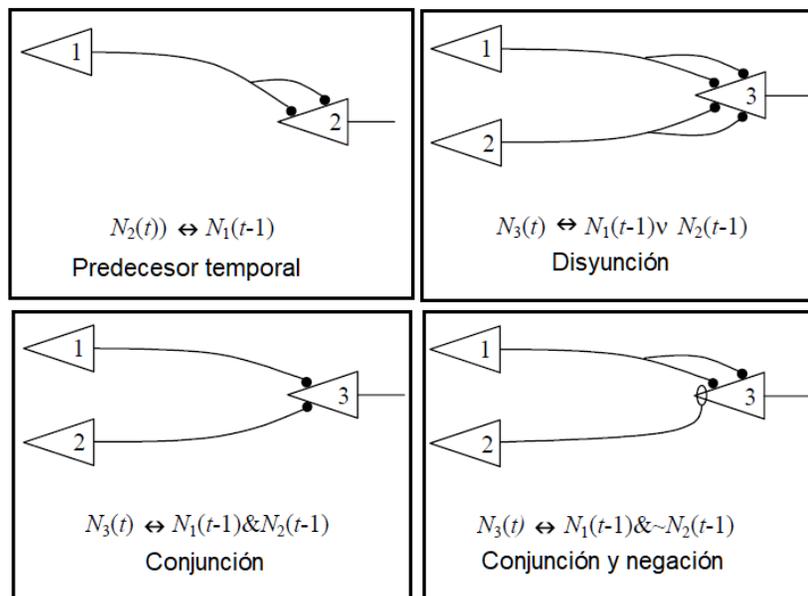


Figura 3.31. Diagramas de redes McCulloch y Pitts donde se muestran sus tipos de conexiones lógicas [McCulloch-Pitts, 1943] [Piccinini, 2004][Kleene, 1956]

En la Figura 3.32, la neurona de sensación de calor (3), se dispara, si y sólo si, recibe dos entradas representadas por las líneas que terminan en su cuerpo. Esto sucede cuando la neurona de recepción de calor (1), se dispara o la neurona de recepción de frío (2), se dispara una vez e inmediatamente deja de disparar. Cuando la neurona 2 se dispara dos veces seguidas, las neuronas intermedias (sin numerar) excitan la neurona 4 en lugar de la neurona 3, generando una sensación de frío.

Para resolver el problema de las redes con círculos se procedió de manera análoga a los de las redes sin círculos, pero dado que, la actividad alrededor de un círculo de neuronas puede continuar por un período de tiempo indefinido, las expresiones de la forma $N_i(t)$ implican cuantificación a lo largo del tiempo, por esta razón, las expresiones que describen redes con círculos son más complicadas.

El tratamiento de esta parte de la teoría de McCulloch y Pitts fue oscuro, y casi impenetrable, es por esto por lo que, científicos de la talla de Kleene, para tratar de entender esta teoría, la abordaron desde el principio y de manera independiente.

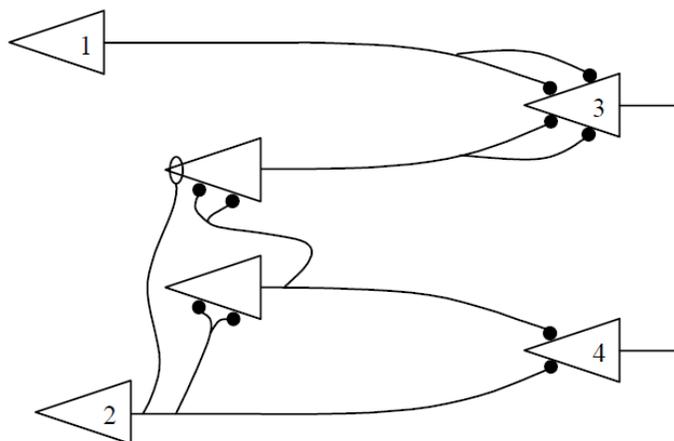


Figura 3.32. Red neuronal de McCulloch y Pitts que explica la ilusión de calor [McCulloch-Pitts, 1943] [Piccinini, 2004]

El desarrollo de McCulloch y Pitts fue adoptado por John von Neumann como parte de lo que ahora se llama Diseño Lógico. Fue el primer trabajo sobre Redes Neuronales y Autómatas. También condujo al desarrollo de Autómatas Finitos, uno de los formalismos más importantes en la teoría de la computación, origen común del enfoque conexionista y clásico de la Inteligencia Artificial Computacional y Redes Neuronales Recurrentes [Piccinini, 2004] [Haykin, 1999].

Para finalizar, me gustaría resaltar a Walter Pitts, el genio matemático que hizo posible esta teoría, dado que, antes de conocer a Warren McCulloch, que de formación era psiquiatra, ya tenía en su haber dos teorías neuronales con otros científicos. Fue un genio incomprendido, un prodigio matemático autodidacta, que quizá por esto último, no fue muy reconocido en su tiempo, porque no lo veían a la altura de otras personalidades con formación universitaria. Pero tampoco hay que minimizar a McCulloch que fue una persona que persiguió un sueño que vio cristalizado en su trabajo conjunto con Pitts. McCulloch en mi opinión, fue el catalizador que encendió el genio creador de Walter Pitts, que tal vez, sin su participación, esta teoría no se hubiera llevado a cabo, al menos con ellos como protagonistas. Referencias para esta sección: [McCulloch-Pitts, 1943] [Piccinini, 2004] [Kleene, 1956] [Rojas, 2001] [Minsky, 1967] [Haykin, 1999].

3.10. Redes Neuronales Artificiales de primera y segunda generación

De manera general, una Red Neuronal Artificial, también referida como “Neurocomputación”, “Redes Conexionistas”, “Procesadores Paralelos Distribuidos”, entre otros, es una máquina que está diseñado para modelar la forma en que el cerebro realiza una tarea o función de interés, a través de un *proceso de aprendizaje*, utilizando configuraciones específicas que forman una red de unidades de computación llamadas “neuronas” con interconexiones masivas entre ellas. Para la implementación de la red neuronal se utilizan componentes electrónicos o bien, es simulada en software en una computadora digital [Haykin, 1999] [Hertz, 1991].

La **primera** y **segunda generación** de Redes Neuronales Artificiales (RNA), están basadas en el modelo neuronal de McCulloch y Pitts, abordado en la Sección 3.9. Este modelo, fue inspirado en parte en características notables de las neuronas biológicas, y en parte en su salida, es decir en comportamientos bien definidos, porque a McCulloch y Pitts no les interesaba describir el funcionamiento de las neuronas biológicas, sino explicar los procesos mentales en términos de mecanismos neuronales, razón por la cual, realizaron un conjunto de simplificaciones e idealizaciones en relación con las propiedades conocidas de las neuronas y las redes neuronales, que les permitieran utilizar la lógica, de manera que, inferencias proposicionales pudieran mapearse en eventos neuronales y viceversa [McCulloch-Pitts, 1943] [Piccinini, 2003] [McCulloch-Pitts, 1943].

En un modelo estándar de una neurona artificial, que forma la base para diseñar Redes Neuronales Artificiales, y que **engloban** a la **primera** y **segunda generación**, se puede identificar tres elementos básicos más una entrada fija externa (Figura 3.33):

1) Un conjunto de entradas, sinapsis, enlaces de conexión o señales x_j , cada uno de los cuales es ponderada con un “peso sináptico” o simplemente *peso* w_{kj} , donde el primer subíndice k se refiere a la neurona actual k , y el segundo se refiere a la entrada j , de manea que la señal x_j , es multiplicada por el peso sináptico w_{kj} en la forma $w_{kj}x_j$. El peso sináptico de una neurona artificial puede tener valores tanto negativos como positivos.

2) Un sumador o integrador para sumar las señales ponderadas de entrada a la neurona k , lo que constituyen un combinador lineal u_k para cada neurona k , de manera que, de acuerdo con el inciso anterior, para m entradas, cada una con m “pesos” sinápticos, se tiene: $u_k = \sum_{j=1}^m w_{kj}x_j$. El combinador lineal u_k podría interpretarse como el equivalente al potencial de membrana en las neuronas biológicas.

3) Una *función de activación* (φ) que acota en un rango permisible la amplitud de la señal de salida de la neurona, a un valor finito, típicamente en $[0,1]$ o en $[-1, 1]$. La función de activación constituye la salida y_k de la neurona k , y su argumento es el combinador lineal u_k , de manera que $y_k = \varphi(u_k) = \varphi(\sum_{j=1}^m w_{kj}x_j)$, de esta forma: $y_k = \varphi(\sum_{j=1}^m w_{kj}x_j)$.

4) Se suele incluir en la unidad neuronal estándar k , una entrada ponderada fija externa llamada **bias**, denotada por b_k , con ponderación w_{k0} ($w_{k0} \neq 0 \therefore b_k \neq 0$) y la señal o entrada $x_0 = +1$, de esta manera, $b_k = w_{k0}x_0 = w_{k0}$. El bias tiene el efecto de aumentar o disminuir la entrada neta de la función de activación, dependiendo de si es positiva o negativa, respectivamente, de esta manera, el *bias* representa una neurona extra en cada capa de la red neuronal. Esto es equivalente a realizar una transformación afín al combinador lineal u_k , de manera que el nuevo combinador lineal v_k llamado **potencial de activación** de la neurona k , o también en ocasiones llamado **campo local inducido** (debido a que se altera de manera externa) está dado por: $v_k = u_k + b_k$. Con esta transformación, la salida de la neurona k se describe como: $y_k = \varphi(v_k) = \varphi(u_k + b_k)$. Se puede escribir el combinador lineal como (3.22).

$$v_k = u_k + b_k = \sum_{j=1}^m w_{kj}x_j + b_k = \sum_{j=1}^m w_{kj}x_j + w_{k0} = \sum_{j=0}^m w_{kj}x_j \quad (3.22)$$

La salida de la neurona k , bajo esta transformación es ahora (3.23).

$$y_k = \varphi(v_k) = \varphi\left(\sum_{j=0}^m w_{kj}x_j\right) \quad (3.23)$$

El incluir el bias, en la neurona estándar, asegura que la neurona tendrá una salida diferente de cero, aun cuando u_k sea igual a cero, dado que $v_k = u_k + b_k$ y $b_k \neq 0$. Si no existe bias, $b_k = 0$.

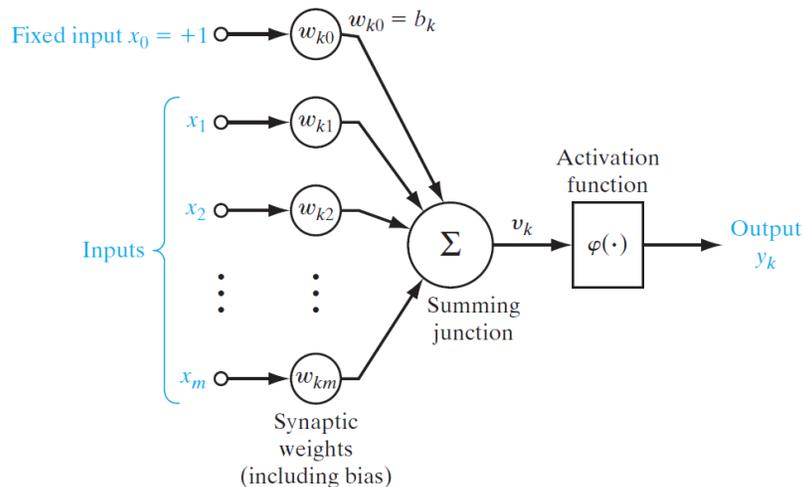


Figura 3.33. Modelo de una neurona artificial [Haykin, 2009]

Los primeros tres elementos pueden encontrar sus contrapartes en las neuronas biológicas en las cuales fueron inspiradas, porque según la Sección 3.6, tienen una región de entradas (señales eléctricas), una región sumadora de las señales entrantes, y una región de disparo o zona de activación, que sería el equivalente a la función de activación que evalúa el resultado del sumador, de acuerdo a un cierto valor de umbral del potencial de membrana, que determina si la neurona se dispara o no (Figura 3.30).

La primera y segunda generación de Redes Neuronales Artificiales se diferencian en el tipo de función de activación [Haykin, 2009] [Hertz, 1991].

La **primera generación** de Redes Neuronales Artificiales utiliza como función de activación $\varphi(v)$, la *función de umbral* llamada también función escalón o función de Heaviside $\varphi(v) = \begin{cases} 1 & \text{si } v \geq 0 \\ 0 & \text{si } v < 0 \end{cases}$. Ver Figura 3.34 y Ecuación (3.24).

$$y_k = \varphi(v_k) = \begin{cases} 1 & \text{si } v_k \geq 0 \\ 0 & \text{si } v_k < 0 \end{cases} \quad (3.24)$$

De acuerdo con esto, la salida de la neurona modelo en esta primera generación se da como la Figura 3.34. La salida de 1 o 0 en la neurona modelo de la primera generación,

refleja la propiedad de todo o nada de la neurona de McCulloch y Pitts, fundamento de estas redes neuronales.

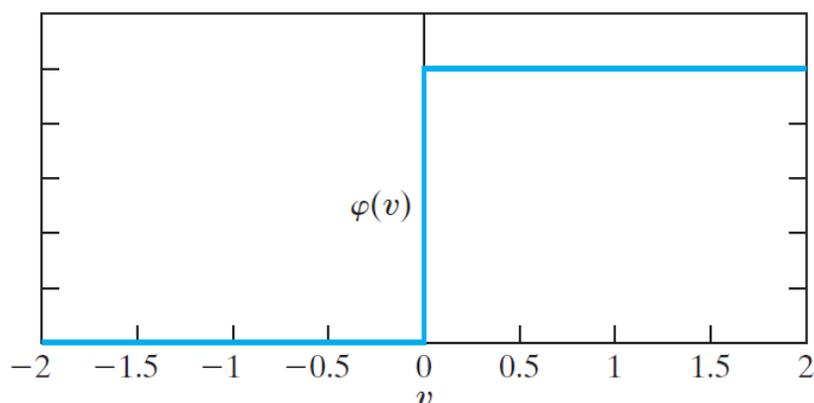


Figura 3.34. Función escalón [Haykin, 2009]

A la primera generación de estas unidades de computación también se les llama *Perceptrones* o *compuertas de umbral*, a la que pertenecen una variedad de modelos de redes neuronales, como los Perceptrones multicapa llamados (también “circuitos de umbral”), Redes de Hopfield y Máquinas de Boltzmann. Este paradigma de redes neuronales se caracteriza porque su salida es digital (0 o 1). Se dice que estos modelos son *universales* para realizar computaciones con entradas digitales, y las funciones booleanas pueden ser calculadas con un Perceptron multicapa con una sola *capa oculta* [Maass, 1997] [Haykin, 1999] [Rojas, 2001] [Hertz, 1991] [McCulloch-Pitts, 1943].

En el caso de la **segunda generación** de Redes Neuronales Artificiales se basa en unidades computacionales que aplican una función de activación con un conjunto continuo de posibles valores de salida a la suma ponderada en las entradas. La *función sigmoide* es el tipo de función más comúnmente utilizada como función de activación $\varphi(v)$, sobresaliendo de manera notable entre este grupo de funciones, la *función sigmoide logística* (Figura 3.35) y la *función sigmoide tangente inversa*.

El grupo de funciones sigmoide comparten muchas características, en particular, la función logística, como función de activación $\varphi(v)$, está dada como (3.25), donde a es el parámetro llamado *pendiente*.

$$\varphi(v) = \frac{1}{1 + e^{(-av)}} \quad (3.25)$$

La función sigmoide logística es creciente y diferenciable en todo su dominio, lo cual es importante a la hora de aplicar algún *algoritmo de aprendizaje*. Esta acotada por dos asíntotas horizontales en $\varphi(v) = 0$ y en $\varphi(v) = 1$, es decir: cuando $v \rightarrow -\infty$, $\varphi(v) \rightarrow 0$, también, si $v \rightarrow +\infty$, $\varphi(v) \rightarrow 1$. Su derivada, esencial en el *algoritmo de aprendizaje*, es: $\varphi'(v) = a \varphi(v)[1 - \varphi(v)]$. La grafica de la función sigmoide logística tiene forma de "s", que varía al variar el parámetro "a", y la grafica de su derivada tiene forma de campana. La función sigmoide tangente inversa posee características similares, pero esta acotada por las asíntotas horizontales en $\varphi(v) = -1$ y en $\varphi(v) = 1$.

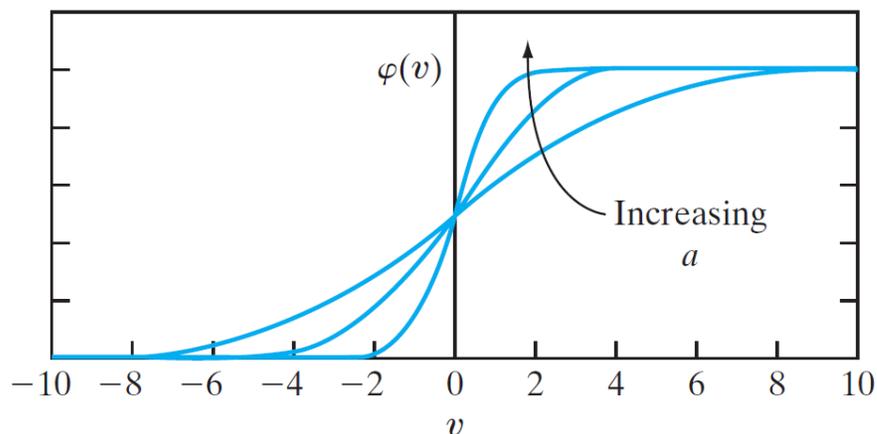


Figura 3.35. Función Sigmoide Logística [Haykin, 1999]

Hay una serie de ventajas y desventajas al utilizar las anteriores funciones como funciones de activación, por esta razón se ha investigado más al respecto, sobresaliendo las funciones ReLu, Leaky ReLu, SoftMax, Elu [Nwankpa, 2018], entre otras, sobre todo en aplicaciones con Deep Learning.

Las redes neuronales de la segunda generación son capaces de computar cualquier función de entrada y salida análogas. Al respecto se dice que son universales en el sentido de que cualquier función continua con dominio y rango compactos puede ser aproximada arbitrariamente bien por una red de este tipo con una sola capa oculta, y, además, admiten algoritmos de aprendizaje basados en el descenso del gradiente o

Backpropagation. La propiedad que es de importancia primordial para una red neuronal es la capacidad para aprender de su entorno y mejorar su rendimiento a través del proceso aprendizaje. El procedimiento utilizado para llevar a cabo el proceso de aprendizaje se llama **algoritmo de aprendizaje**. La función del algoritmo de aprendizaje es la de modificar los pesos sinápticos de la red de manera ordenada a fin de alcanzar un objetivo de diseño deseado. El diseño de redes neuronales dependerá del tipo de modificación de los pesos sinápticos. En otras palabras, la forma en que se estructuran las neuronas de una red neuronal está íntimamente relacionada con el algoritmo de aprendizaje utilizado para entrenar la red [Maass, 1997] [Haykin, 1999].

El algoritmo LMS (Least-Mean-Square) fue sustancial para el desarrollo del Teorema de Convergencia del Perceptron y del algoritmo de propagación hacia atrás (Backpropagation) para el entrenamiento del Perceptron multicapa (Multilayer Perceptron), dos algoritmos de aprendizaje fundamentales en el desarrollo de las Redes Neuronales Artificiales [Haykin, 1999]. Hay una gran variedad de algoritmos de aprendizaje dentro de sus dos paradigmas: Aprendizaje supervisado y no supervisado. Referencias para esta sección: [Llonen, 2003][Charalambous, 1992][Hagan, 1994][Al-Hasanat, 2014][Haykin, 1999][Hertz, 1991][Arbib, 2002][Arbib, 1987].

3.11. Redes Neuronales Artificiales de tercera generación

Los sistemas neuronales biológicos utilizan potenciales de acción (spikes) para codificar información (Secciones 3.6 y 3.8). Estos resultados experimentales de la neurobiología han llevado a la investigación de una tercera generación de modelos de redes neuronales que emplean neuronas “*pulsantes*” (*spiking neurons*), o también llamadas “*neuronas de integración y disparo*” (*integrated-and-fire neurons*) como unidades computacionales.

Los modelos matemáticos fenomenológicos similares a los de integración y disparo (o pulsantes) se pueden rastrear hasta [Lapicque, 1907], que intento predecir el potencial de acción después del inicio del estímulo, aunque su modelo carecía del reinicio del potencial de membrana después del disparo. Después de Lapicque se pueden nombrar a [Hill, 1936] [McCulloch-Pitts, 1943].

Una línea diferente de modelos matemáticos neuronales son los modelos biofísicos, que tienen su origen en el modelo desarrollado por primera vez por Hodgkin y Huxley en 1952. Las ecuaciones que representan el modelo neuronal de Hodgkin-Huxley (Sección 3.8), son el punto de partida no sólo para modelos neuronales detallados en el campo de neurofisiología o en neurociencia teórica, sino también es un modelo de referencia para la derivación de modelos neuronales simplificados. Estos modelos simplificados se centran en unos pocos aspectos de las neuronas biológicas, sin embargo, en comparación con los dos modelos anteriores de la primera y segunda generación de Redes Neuronales Artificiales, son sustancialmente más realistas. En particular, describen mucho mejor el rendimiento real de una neurona biológica y, por lo tanto, permiten investigar en un nivel teórico, las posibilidades de utilizar el tiempo como un recurso para la computación y la comunicación, aspecto que se dejaba de lado en las dos anteriores generaciones.

El potencial de membrana permanece sin cambio si no hay entradas que perturben su potencial de equilibrio, o de reposo (Sección 3.7). Una entrada excitatoria produce una despolarización en el potencial de membrana (lo vuelve menos negativo), y una entrada inhibitoria produce una hiperpolarización en su potencial de membrana (lo vuelve más negativo).

Si se considera un análisis de la relación entre una neurona postsináptica i , y una neurona presináptica j , y si ahora se denomina $u_i(t)$ como el potencial de membrana de la neurona i , entonces $u_i(t)$ representa el potencial interno de la membrana, dado que se definió el potencial en el exterior como cero (Sección 3.7). También, u_r es el potencial de reposo de la membrana, que, para una neurona típica, $u_r = -65mV$, es decir, $u_i(0) = u_r = -65mV$.

Si en $t = 0$ la neurona presináptica dispara un potencial de acción (pulso o spike), para $t > 0$ el potencial de la membrana postsináptica cambia su potencial respecto a su potencial de reposo en la forma: $u_i(t) - u_r = \varepsilon_{ij}(t)$, donde $\varepsilon_{ij}(t)$ es el cambio en el potencial de membrana de la neurona postsináptica, o simplemente, de la neurona i , debido al potencial de acción generado por la neurona presináptica, o simplemente, de la neurona j . Si $\varepsilon_{ij}(t) > 0$ el potencial postsináptico es excitatorio, si $\varepsilon_{ij}(t) < 0$, es inhibitorio.

Para unas pocas neuronas presinápticas que disparan unos pocos potenciales de acción que inician en el tiempo t_j^f , el cambio en el potencial de membrana en una neurona postsináptica i , es lineal en la forma: $u_i(t) = \sum_j \sum_f \varepsilon_{ij}(t - t_j^f) + u_r$. Cuando el número de pulsos de entrada aumenta de manera considerable en un intervalo corto de tiempo, el potencial $u_i(t)$ deja de ser lineal. Tan pronto como $u_i(t)$ rebasa un cierto valor crítico ϑ , llamado umbral, como ya se mencionó, la neurona i exhibe un comportamiento en forma de un pulso corto e intenso (muy diferente a una suma de potenciales) que se propaga a lo largo del axón de la neurona i , hacia la sinapsis con otras neuronas. El tiempo de disparo t_i^f lo define el momento en que se cruza el umbral de la neurona i . Mediante una primera y burda aproximación, la dinámica neuronal se puede concebir como un proceso de suma (llamado también proceso de “integración”).

Según la Sección 3.6, la forma del potencial de acción no se puede utilizar para transmitir información, dado que no cambia, en vez de eso, la información se codifica por la presencia o ausencia del potencial de acción, de esta manera, los potenciales de acción se reducen a *eventos* que suceden en un preciso momento en el tiempo. Los modelos neuronales cuyos potenciales de acción se describen como eventos, se les llama “modelos neuronales de integración y disparo” (*integrate-and-fire models*), los cuales, para conocer su dinámica, se debe conocer $u_i(t)$ que describa la evolución de su potencial de membrana, y un mecanismo para generar potenciales de acción [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002].

3.11.1. Modelo Neuronal de Integración y Disparo con Fugas (leaky integrate-and-fire model)

El modelo “más simple y básico” de los modelos de integración y disparo es un modelo lineal que se le llama “modelo de integración y disparo con fugas” (*leaky integrate-and-fire model*), en el cual se describe el potencial de membrana $u_i(t)$, como una ecuación diferencial lineal, y posee un umbral de disparo.

El potencial de membrana de una neurona cambia debido a entradas sinápticas de otras neuronas, o también, si el experimentador le inyecta un pulso de corriente $I(t)$. De esta manera, el circuito eléctrico básico que representa un modelo de integración y disparo con fugas consiste en un capacitor C en paralelo con una resistencia R impulsada

por la corriente $I(t)$ (ver Sección 3.8). La ecuación diferencial que describe la evolución del potencial de membrana (ver Sección 3.8), del modelo neuronal “integración y disparo, con fugas” (*leaky integrate-and-fire neuron model*) está dado por:

$$\tau_m \frac{du}{dt} = -[u(t) - u_r] + RI(t) \quad (3.26)$$

con la condición de reinicio:

$$\lim_{\delta \rightarrow 0; \delta > 0} u(t^f - \delta) = u_r \quad (3.27)$$

donde t^f son los tiempos de disparo (condición de umbral):

$$t^f = \{t: u(t^f) = \vartheta\} \quad (3.28)$$

$\tau_m = RC$ es la constante de tiempo de la membrana.

Solución a). Para las condiciones iniciales $u(t_0) = u_r + \Delta u$, la solución de la ecuación diferencial es:

$$u(t) - u_r = \Delta u \exp\left(-\frac{t - t_0}{\tau_m}\right) \text{ para } t > t_0 \quad (3.29)$$

Lo que significa que en ausencia de entradas el potencial de membrana decae a su valor de reposo.

Solución b): Para un pulso de corriente constante $I(t) = I_0$, y con las condiciones iniciales $u(0) = u_r$ y $t > \Delta$ (Δ es la duración del pulso de corriente) la solución es:

$$u(t) = u_r + RI_0 \left[1 - \exp\left(-\frac{t}{\tau_m}\right)\right] \quad (3.30)$$

Para pulsos de corriente que tomen mucho tiempo, se alcanza el estado estacionario.

Se puede dar una solución más general para este caso si se consideran pulsos de tiempo muy pequeños respecto a Δ , y rescribiendo la ecuación diferencial (3.26), como:

$$\tau_m \frac{du}{dt} = -[u(t) - u_r] + Rq\delta(t) \quad (3.31)$$

donde $\delta(t)$ es la función $\delta(t)$ de Dirac.

con $u(t) = u_r$ para $t < \Delta$ y,

$$u(t) - u_r = \frac{qR}{\tau_m} \exp\left(-\frac{t}{\tau_m}\right) \text{ para } t > \Delta \quad (3.32)$$

Se puede denotar un tren de pulsos de la neurona i como una secuencia de tiempos de disparo, en la forma:

$$S_i(t) = \sum_f \delta(t - t_i^f) \quad (3.33)$$

donde f etiqueta los pulsos. Esto reduce los pulsos a puntos en el tiempo.

Solución c). $I(t)$ es una corriente de entrada arbitraria dependiente del tiempo. La solución tiene la forma:

$$u(t) = u_r + \sum_f (u_r - \vartheta) \exp\left(-\frac{t - t_i^f}{\tau_m}\right) + \frac{R}{\tau_m} \int_0^\infty \exp\left(-\frac{s}{\tau_m}\right) I(t - s) ds \quad (3.34)$$

El estudio del modelo Hodgkin-Huxley normalmente se limita a simulaciones numéricas por lo difícil del análisis de un sistema de cuatro ecuaciones diferenciales. Sin embargo, un análisis matemático es posible para un sistema de dos ecuaciones diferenciales, para lo cual, la estrategia es una reducción sistemática del modelo de Hodgkin-Huxley de cuatro a dos dimensiones, eliminando dos de las cuatro variables [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002].

3.11.2. Modelo Neuronal General de Hodgkin-Huxley en dos Dimensiones

(integrate-and-fire general model in two dimensions)

En la Figura 3.36 se puede observar el comportamiento de la variable de activación m y la variable de inactivación h respecto al tiempo, del modelo matemático de Hodgkin-Huxley (Sección 3.8).

La escala de tiempo relativamente rápida de m sugiere que m se puede tratar como una variable *instantánea* (ver Figura 3.36). Por lo tanto, la variable m en la ecuación (3.20a) del modelo de Hodgkin-Huxley, puede reemplazarse por su valor de estado estable, $m(t) \rightarrow m_0[u(t)]$ (aproximación de estado cuasiestacionario).

En la Figura 3.27B (Sección 3.8) se puede observar que las constantes de tiempo τ_m y τ_h tienen una dinámica muy similar sobre el voltaje u (en esa figura $u = V$). Además, las gráficas de $n_0(u)$ y $1 - h_0(u)$ en la Figura 3.36B también son muy similares. Lo que sugiere que se puede aproximar las variables n y $(1 - h)$ mediante una única variable efectiva w . De manera más general, se hace una aproximación lineal $(b - h) \approx an$ con las constantes a, b , de manera que $w = b - h = an$. Así, $h = b - w$ y $n = w / a$ que, con la primera aproximación, $m = m_0(u)$, se sustituyen en la ecuación (3.18) del modelo matemático de Hodgkin y Huxley para obtener:

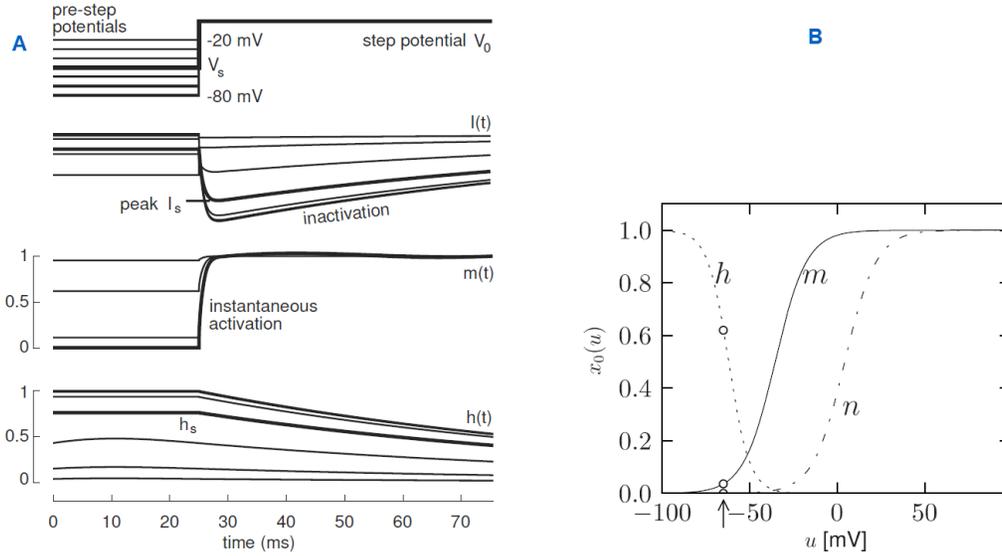


Figura 3.36. A) Dinámica de la corriente I , la variable de activación m y la variable de inactivación h en el experimento a voltaje fijo (voltage-clamp) de Hodgkin-Huxley para medir h_∞ (ver Figura 3.27A) [Izhikevich, 2007]. B) Funciones de equilibrio para las variables m, n, h en el modelo de Hodgkin-Huxley, la flecha señala el potencial de reposo: $u = -65\text{mV}$ [Gerstner-Kistler, 2014]

$$C \frac{du}{dt} = -g_{Na}[m_0(u)]^3(b-w)(u-E_{Na}) - g_K\left(\frac{w}{a}\right)^4(u-E_K) - g_l(u-E_l) + I \quad (3.35)$$

Multiplicando toda la ecuación por $R = g_l^{-1}$ y dividiendo entre $\tau = RC$, la ecuación anterior se puede escribir en forma compacta:

$$\frac{du}{dt} = \frac{1}{\tau} [F(u, w) + RI] \quad (3.36)$$

donde $F(u, w)$ es una función que representa los primeros dos términos de la ecuación (3.35).

De las ecuaciones (3.18a) (Sección 3.8), se puede eliminar la correspondiente a m , dado que es una variable instantánea. Las ecuaciones restantes para n y h , se pueden combinar para formar una única ecuación efectiva (3.37), donde τ_w es un parámetro y G una función que interpola entre dn/dt y dh/dt (los pasos precisos son muy laboriosos para presentarse aquí, ver [Gerstner-Kistler, 2014]).

$$\frac{dw}{dt} = \frac{1}{\tau_w} G(u, w) \quad (3.37)$$

De esta manera, las ecuaciones (3.36) y (3.37), que se muestran nuevamente como el sistema de ecuaciones (3.38), definen el modelo neuronal general de Hodgkin-Huxley en dos dimensiones:

$$\left. \begin{aligned} \frac{du}{dt} &= \frac{1}{\tau} [F(u, w) + RI] \\ \frac{dw}{dt} &= \frac{1}{\tau_w} G(u, w) \end{aligned} \right\} \quad (3.38)$$

donde $F(u, w)$ y $G(u, w)$ se pueden extraer del mismo modelo [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002] [Izhikevich, 2007].

3.11.3. Modelo de Morris–Lecar (1981)

Este modelo neuronal biológico basado en estudios de un crustáceo (barnacla gigante), da una descripción fenomenológica del potencial de acción. Es atractivo debido a su simplicidad matemática, y por lo mismo, es ampliamente utilizado en la investigación de neurociencia computacional, y aunque se dice que no se deriva directamente del modelo de Hodgkin-Huxley, su estructura es bastante similar que pareciera que fue derivado de este modelo. El modelo propuesto por Morris-Lecar es el siguiente:

$$\left. \begin{aligned} C \frac{du}{dt} &= -g_{Ca} m_0(u) (u - u_{Ca}) - g_K w_0(u) (u - u_K) - g_l (u - u_l) + I \\ \frac{dw}{dt} &= -\frac{1}{\tau(u)} [w - w_0(u)] \end{aligned} \right\} \quad (3.39)$$

donde:

$$\left. \begin{aligned} m_0(u) &= \frac{1}{2} \left[1 + \tanh \left(\frac{u - u_1}{u_2} \right) \right] \\ w_0(u) &= \frac{1}{2} \left[1 + \tanh \left(\frac{u - u_3}{u_4} \right) \right] \\ \tau(u) &= \frac{\tau_w}{\cosh \left(\frac{u - u_3}{2u_4} \right)} \end{aligned} \right\} \quad (3.39a)$$

donde u_1, u_2, u_3 y u_4 son parámetros de ajuste para el estado estacionario y constante de tiempo. La primera ecuación describe la evolución del potencial de membrana u . La segunda ecuación describe la evolución de la variable de “recuperación” lenta, w . La tercera ecuación se utiliza para aproximar la constante de tiempo mediante otro parámetro τ_w . El resto de las variables, son como en el modelo de Hodgkin-Huxley [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002] [Izhikevich, 2007].

3.11.4. Modelo de Fitzhugh–Nagumo (1961)

El modelo de Fitzhugh–Nagumo [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002] [Izhikevich, 2007] [Lindblad, 2005], es una versión del modelo de Hodgkin-Huxley en dos dimensiones, en el que $F(u, w) = u - \frac{1}{3}u^3 - w$ y $G(u, w) = b_0 - b_1u - w$, de manera que el modelo completo esta dado como:

$$\left. \begin{aligned} \tau \frac{du}{dt} &= u - \frac{1}{3}u^3 - w + RI \\ \tau_w \frac{dw}{dt} &= b_0 - b_1u - w \end{aligned} \right\} \quad (3.40)$$

3.11.5. Modelos no Lineales de Integración y Disparo (*Nonlinear Integrate-and-Fire Models*)

En los modelos de integración y disparo generalizados, se generan potenciales de acción (spikes) siempre que el potencial de membrana u cruza algún umbral θ_{reset} . El momento de cruce del umbral define el tiempo de disparo t^f .

$$t^f: u(t^f) = \theta_{reset} \quad \text{y} \quad \left. \frac{du(t)}{dt} \right|_{t=t^f} > 0 \quad (3.41)$$

La caída del potencial de acción se reemplaza por un reinicio algorítmico del potencial de membrana a un nuevo valor u_r cada vez que se alcanza el umbral θ_{reset}

La duración de un potencial de acción se reemplaza (aunque no siempre) por un tiempo refractario absoluto Δ^{abs} ($0 < \Delta^{abs} < 5ms$), después de cada pulso (spike), antes de que la dinámica del potencial de membrana se reinicie con $u = u_r$ como condición inicial.

En un modelo no lineal de integración y disparo generalizado (en una variable), el potencial de membrana evoluciona de acuerdo con: $\frac{du}{dt} = f(u) + R(u)I$ aunque normalmente se supone una resistencia eléctrica de entrada constante, independiente del voltaje, es decir, $R(u) = R$ [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002].

3.11.6. Modelo de Integración y Disparo Exponencial (*Exponential integrate-and-fire model*)

En este modelo la ecuación diferencial que gobierna la evolución del potencial de membrana esta dado como:

$$\tau \frac{du}{dt} = -(u - u_r) + \Delta_T \exp\left(\frac{u - \vartheta_{rh}}{\Delta_T}\right) + RI \quad (3.42)$$

donde el primer término del lado derecho de la ecuación representa la fuga del modelo de membrana pasiva (*leaky integrate-and-fire neuron model*, ecuación (3.26)). La no linealidad del modelo lo representa el término exponencial. Δ_T es el parámetro de “nitidez”, y ϑ_{rh} es el “umbral” (se ha encontrado que en neuronas reales no existe un umbral definido de disparo).

Como se mencionó, el momento en que el potencial de membrana alcanza el umbral numérico θ_{reset} , define el tiempo de disparo t^f , de manera que después del disparo, el potencial de membrana se reinicia a u_r (el potencial de reposo), y un nuevo disparo empieza después de un periodo $t^f + \Delta^{abs}$ (Δ^{abs} periodo absoluto refractario). El umbral θ_{reset} se introduce principalmente por conveniencia numérica (recordar que no existe un umbral definido en neuronas reales) [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002].

3.11.7. Modelo de Integración y Disparo Cuadrático (*Quadratic integrate-and-fire model*)

En este modelo la ecuación diferencial que gobierna la evolución del potencial de membrana esta dado como:

$$\tau \frac{du}{dt} = (u - u_r)(u - u_c) + RI \quad (3.43)$$

con parámetros a_0 y u_c , donde $a_0 > 0$ y $u_c > u_r$. Con las condiciones iniciales $I = 0$ y $u < u_c$ el voltaje decae al potencial de reposo u_r . Si $u > u_c$, el potencial se incrementa de manera que se dispara un potencial de acción. Se puede interpretar u_c como un voltaje crítico que inicia un potencial de acción debido a un pequeño pulso de corriente [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002] [Izhikevich, 2007].

3.11.8. Modelo de Integración y Disparo Adaptativo Exponencial (*Adaptive exponential integrate-and-fire*)

En las neuronas de integración y disparo no lineales, la dinámica de voltaje de membrana se caracteriza por una sola función $f(u)$. Una sola ecuación no es suficiente para la variedad de patrones de disparo que exhiben las neuronas en respuesta a pasos de corriente. Es por esto por lo que se acopla la ecuación de voltaje a *variables de corriente abstractas*, cada una descrita por una ecuación diferencial lineal. El modelo de integración y disparo exponencial adaptativo consiste en una no linealidad exponencial en la ecuación de voltaje acoplada a una única variable de adaptación w .

$$\left. \begin{aligned} \tau_m \frac{du}{dt} &= -(u - u_r) + \Delta_T \exp\left(\frac{u - \vartheta_{rh}}{\Delta_T}\right) - R w + R I(t) \\ \tau_w \frac{dw_k}{dt} &= -a(u - u_r) - w + b \tau_w \sum_{t^f} \delta(t - t^f) \end{aligned} \right\} \quad (3.44)$$

Después de cada disparo, el voltaje se restablece a $u = u_r$ y la variable de adaptación w aumenta en una cantidad b . El parámetro a se relaciona con la adaptación del subumbral dado que acopla la adaptación al voltaje. La adaptación activada por potenciales de acción se controla mediante una combinación de a y b . La elección de a y b determina en gran medida los patrones de disparo de la neurona [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002].

3.11.9. Modelo de Izhikevich (*Izhikevich model*)

El modelo de Izhikevich es una combinación de los modelos de integración y disparo cuadrático y exponencial adaptativo [Gerstner-Kistler, 2014] [Gerstner-Kistler, 2002][Izhikevich, 2007]. Consiste en un sistema de ecuaciones diferenciales en el que utiliza el modelo de integración y disparo cuadrático en la primera ecuación del modelo de integración y disparo adaptativo. Si $u = \theta_{reset}$, el voltaje se restablece a $u = u_r$ y la variable de adaptación w aumenta en una cantidad b . Normalmente b es positivo, aunque valores negativos no se descartan.

El modelo de Izhikevich con las características anteriores está dado según las ecuaciones (3.45).

$$\left. \begin{aligned} \tau_m \frac{du}{dt} &= (u - u_r)(u - \vartheta) - Rw + RI(t) \\ \tau_w \frac{dw_k}{dt} &= -a(u - u_r) - w + b\tau_w \sum_{t^f} \delta(t - t^f) \end{aligned} \right\} \quad (3.45)$$

El modelo de Izhikevich, como se conoce normalmente, es adimensional, y los fundamentos matemáticos para llegar a él, se encuentran en [Izhikevich, 2008] [Izhikevich, 2000]. Una de las presentaciones de su modelo es la siguiente:

$$\left. \begin{aligned} \frac{dv}{dt} &= 0.05v^2 + 5v + 140 - u + I \\ \frac{du}{dt} &= a(vb - u) \\ \text{con la condición de reinicio} \\ \text{si } v \geq 30 \text{ entonces } &\begin{cases} v \leftarrow c \\ u \leftarrow u + d \end{cases} \end{aligned} \right\} \quad (3.46)$$

En esta presentación del modelo, v y u son variables adimensionales, al igual que los parámetros a, b, c, d . La variable v denota el potencial de membrana y u representa una variable de recuperación de membrana que depende del valor de a (normalmente $a = 0.02$). La variable u contribuye con retroalimentación negativa a v . Después del disparo del pulso v y u se reinician. I representa la corriente de entrada, sea sináptica o inyectada. El valor umbral de la neurona modelo está entre -70 y -60 mV (dependiendo del valor de b). El parámetro b representa la sensibilidad de la variable u a las fluctuaciones subumbrales de v (normalmente $b = 0.2$). El parámetro c se relaciona con el reinicio del potencial de membrana v después del disparo (normalmente $c = -65$ mV). El parámetro d se relaciona con el reinicio de la variable de recuperación u después del disparo (normalmente $d = 2$).

Diferentes elecciones de los parámetros a, b, c, d dan como resultado diferentes patrones de disparo intrínsecos, como los exhibidos por las neuronas neocorticales y talámicas de mamíferos, lo que define también la clasificación del tipo de neuronas, que pueden ser excitatorias e inhibitorias.

Las neuronas corticales de tipo excitatorio se dividen en las siguientes clases (Figura 3.37):

1. *Regular Spiking Neurons* (RS). Presenta una adaptación de frecuencia de pulsos, según la corriente inyectada. En el modelo, $c = -65$ mV y $d = 8$.

2. *Intrinsically Bursting Neurons* (IB). Disparan una ráfaga de pulsos seguido de pulsos individuales repetitivos. En el modelo, $c = -55 \text{ mV}$ y $d = 4$. Durante la ráfaga inicial, la variable u se acumula y eventualmente cambia la dinámica de ráfaga de pulsos.
3. *Chattering Neurons* (CH). Estas neuronas pueden disparar ráfagas estereotipadas de pulsos muy próximos. La frecuencia entre ráfagas puede ser tan alta como 40 Hz . En el modelo, $c = -50 \text{ mV}$ y $d = 2$.

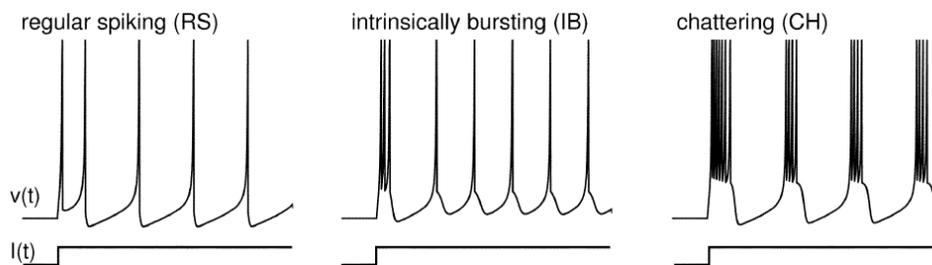


Figura 3.37. Dinámica de disparo de pulsos de las neuronas de tipo excitatorio [Izhikevich, 2003]

Las neuronas corticales de tipo inhibitorio se dividen en las siguientes dos clases (Figura 3.38):

1. *Fast Spiking Neurons* (FS). Estas neuronas pueden disparar trenes periódicos de pulsos con una frecuencia muy alta. En el modelo, $a = 0.1$.
2. *Low-Threshold Spiking Neurons* (LTS). Estas neuronas pueden disparar trenes de pulsos de alta frecuencia. Tienen umbrales de activación bajos ($b = 0.25$ en el modelo).

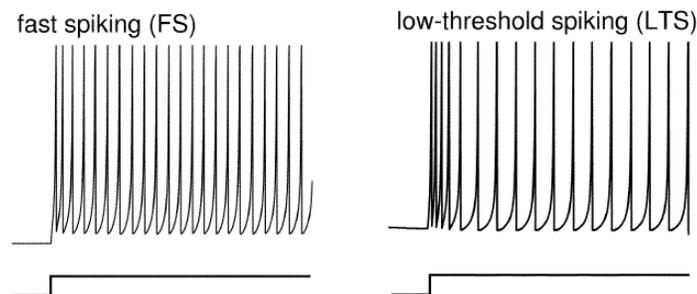


Figura 3.38. Dinámica de disparo de pulsos de las neuronas de tipo inhibitorio [Izhikevich, 2003]

Neuronas Talamocorticales, cuyo comportamiento también puede ser reproducido por este modelo:

1. *Thalamo-Cortical Neurons* (TC). Estas neuronas tienen dos regímenes de disparo: cuando están en reposo ($v \approx -60 \text{ mV}$) y luego se despolarizan, exhiben disparos tónicos (Figura 3.39a). Sin embargo, si el potencial de membrana se hiperpolariza ($v \approx -90 \text{ mV}$) debido a entrada de corriente, las neuronas disparan una ráfaga de rebote de pulsos (Figura 3.39b).
2. *Resonator Neurons* (RZ). Estas neuronas tienen oscilaciones subumbrales amortiguadas o sostenidas (Figura 3.39c). En el modelo $a = 0.1$ y $b = 0.26$.

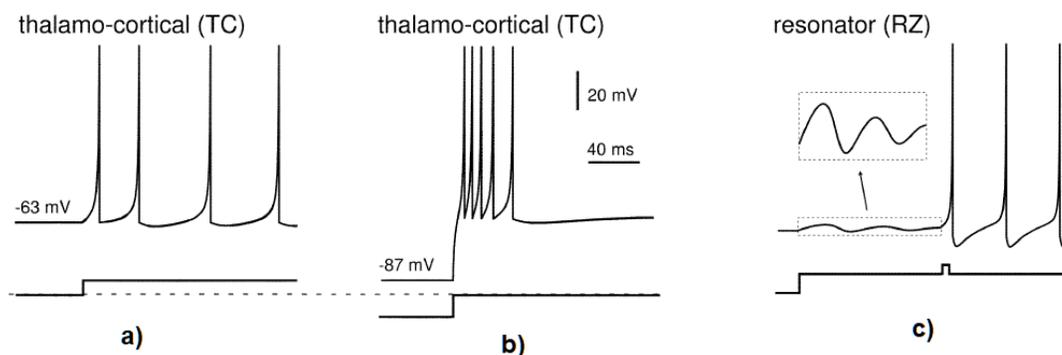


Figura 3.39. Dinámica de disparo de pulsos de las neuronas de tipo inhibitorio [Izhikevich, 2003]

Este modelo también puede representar la dinámica de otras neuronas como las del tallo cerebral, hipocampo, ganglios basales y bulbo olfatorio.

3.11.10. Comparación de las Propiedades Neuro-Computacionales de algunos de los Modelos Pulsantes según Izhikevich

Izhikevich realiza un trabajo [Izhikevich, 2004] en el que analiza la plausibilidad biológica y la eficiencia computacional de algunos de los modelos de neuronas pulsantes más conocidos, y lleva a cabo una comparación y contraste de varios modelos de neuronas pulsantes (Figura 2.3).

Revisa veinte de las características más notables de las neuronas biológicas pulsantes, y se describe la variedad y complejidad de su comportamiento individual en respuesta a pulsos simples de corriente continua, y se observa su potencial de

membrana. Cada modelo se expresa en forma de ecuaciones diferenciales ordinarias escrito como sistema dinámico y se comparan su costo computacional. De todos estos modelos, destaca el Modelo de Izhikevich [Izhikevich, 2003] visto en el apartado anterior. Este modelo puede reproducir todas las características mencionadas, excepto el correspondiente al significado Biofísico, pero su costo computacional es uno de los más bajos (ver el estado del arte capítulo 2: Which Model to Use for Cortical Spiking Neurons? [Izhikevich, 2004]).

3.11.11. Redes Neuronales Pulso-Acopladas (*Pulse-Coupled Neural Networks*)

Otros modelos neuronales biológicos inspirados en estudios de la corteza visual de mamíferos surgieron a finales de los 80's con R. Eckhorn [Eckhorn, 1990] [Lindblad, 2005], que propuso un modelo neuronal biológico basado en estudios de la corteza visual del gato, y a principios de los 90's, I.A. Rybak propuso su modelo neuronal biológico basado en estudios de la corteza visual del cerdo de guinea (conejiillo de indias) [Lindblad, 2005]. Desde un principio se reconoció que estos modelos tenían un gran potencial en el procesamiento de imágenes

Estos descubrimientos abrieron el camino para el surgimiento de las Redes Neuronales Pulso-Acopladas (PCNN), primeramente, propuestas por John L. Johnson, el cual realizó modificaciones y variaciones menores al modelo biológico original de Eckhorn, requeridas para su digitalización, y de esta manera se pudiera emplear en algoritmos de procesamiento de imágenes.

Las Redes Neuronales Pulso-Acopladas están formadas por neuronas del tipo "Integración y disparo" (*Integrate-and-fire neurons*), dado que presentan esta característica, y, además, también su salida es "pulsante", es por esto por lo que las Redes Neuronales Pulso-Acopladas son clasificadas como Redes Neuronales de Tercera Generación, especializadas en el procesamiento de imágenes, campo en el cual no requieren de entrenamiento.

El modelo de Eckhorn (Figura 3.40), consta de dos compartimentos de entrada llamados el *Feeding* (Alimentación) y *Linking* (Enlace). El *Feeding* recibe un estímulo tanto externo como local. El *Linking* recibe un estímulo local. El *Feeding* y el *Linking* se

combinan para crear un voltaje (potencial) de membrana U_m , que representa el estado interno de la neurona, y que se compara con un umbral local θ , para producir la salida.

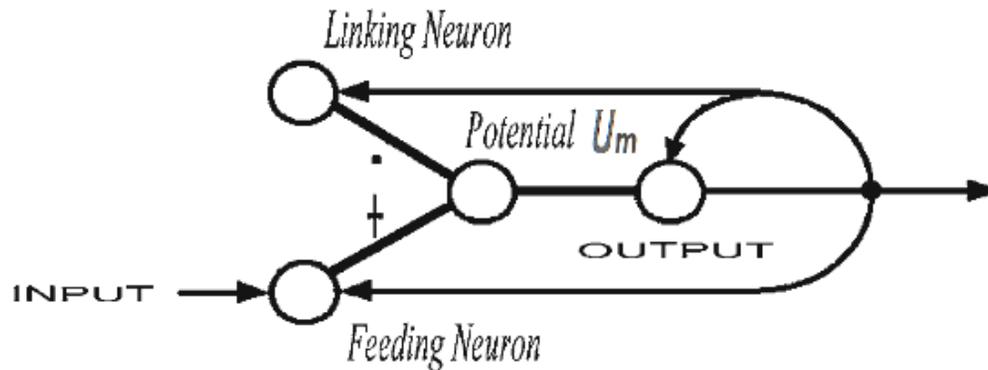


Figura 3.40. Modelo neuronal de Eckhorn [Lindblad, 2005]

La PCNN se basa en gran medida en el modelo *Eckhorn*, excepto por algunas modificaciones requeridas para la digitalización (Figura 3.41).

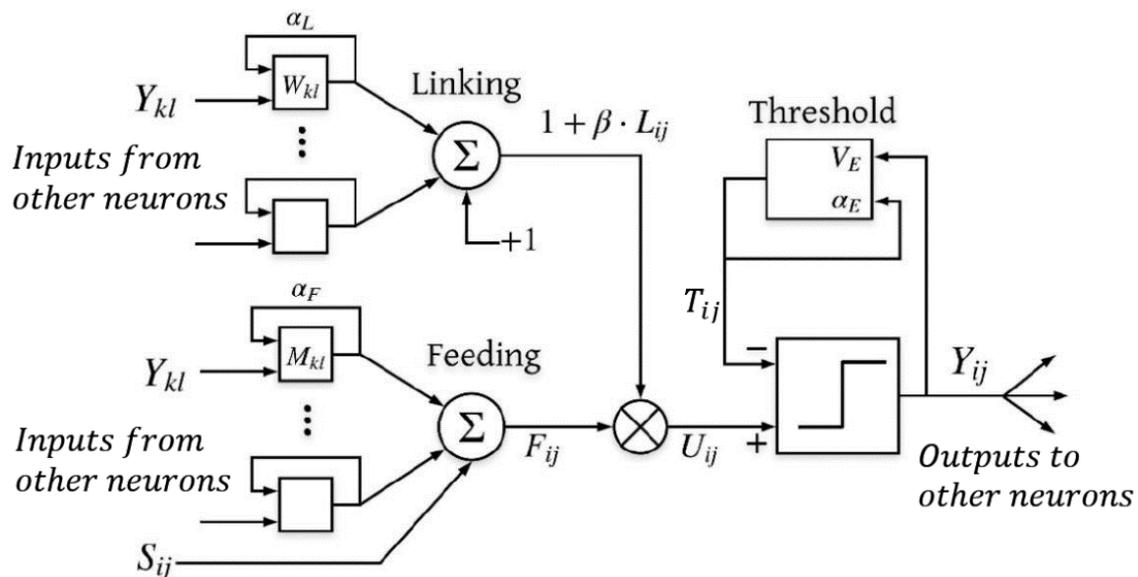


Figura 3.41. Representación esquemática de una neurona PCNN [Lindblad, 2005] [Aguilar, 2019]

El sistema de Ecuaciones (3.47) describe el modelo PCNN [Lindblad, 2005] [Ma, 2010].

$$F_{i,j}[n] = e^{-\alpha F} F_{i,j}[n-1] + V_F \sum_{k,l} M_{i,j,k,l} Y_{k,l}[n-1] + S_{i,j} \quad (3.47a)$$

$$L_{i,j}[n] = e^{-\alpha L} L_{i,j}[n-1] + V_L \sum_{k,l} W_{i,j,k,l} Y_{k,l}[n-1] \quad (3.47b)$$

$$U_{i,j}[n] = F_{i,j}[n](1 + \beta L_{i,j}[n]) \quad (3.47c)$$

$$T_{i,j}[n] = e^{-\alpha T} T_{i,j}[n-1] + V_T Y_{i,j}[n-1] \quad (3.47d)$$

$$Y_{i,j}[n] = \begin{cases} 1 & \text{si } U_{i,j}[n] > T_{i,j}[n-1] \\ 0 & \text{En otro caso} \end{cases} \quad (3.47e)$$

Cada compartimento recibe entradas de sus neuronas vecinas a través de los pesos sinápticos M y W respectivamente según (3.47a) y (3.47b). Cada uno de ellos retiene su estado previo, pero con un factor de decaimiento. Los valores de estos dos compartimentos también están dados por (3.47a) y (3.47b) respectivamente, donde F_{ij} es el *Feeding* de la neurona (i,j) , y L_{ij} es el *Linking*. Las Y_{kl} son las salidas de las neuronas de una iteración anterior $[n-1]$. Los parámetros V_F y V_L son constantes normalizadas.

Como antes, el F_{ij} y el L_{ij} se combinan para crear el estado interno U_{ij} de la neurona, combinación que es controlada por la fuerza β del *Linking*, según (3.47c). Posteriormente este estado interno de la neurona se compara con un umbral dinámico T_{ij} , para producir la salida Y_{ij} , la que es 1 si el estado interno actual de la neurona es mayor que el umbral, de otra manera es 0. Los pesos sinápticos M y W , normalmente son *kernels* (máscaras) de convolución de tipo gaussiano que emulan las interacciones con otras neuronas, y generalmente de una dimensión de 3×3 , dado que aumentar el tamaño no siempre garantiza mejores resultados, pero sí aumento de costo computacional [Lindblad, 2005].

3.12. Segmentación

La segmentación de imágenes es el proceso mediante el cual una imagen es dividida en sus partes constituyentes de acuerdo con sus atributos, como la intensidad de cada píxel, valores espectrales o sus propiedades de textura obteniéndose las regiones más sobresalientes [Ma, 2010] [Lindblad, 2005] [Gonzalez, 2002]. Separar los

objetos del fondo de una imagen mediante binarización, es el proceso básico de la segmentación, lo cual es utilizado para la clasificación y reconocimiento de objetos en diferentes campos de la Visión Artificial (VA), ver Figura 3.42.

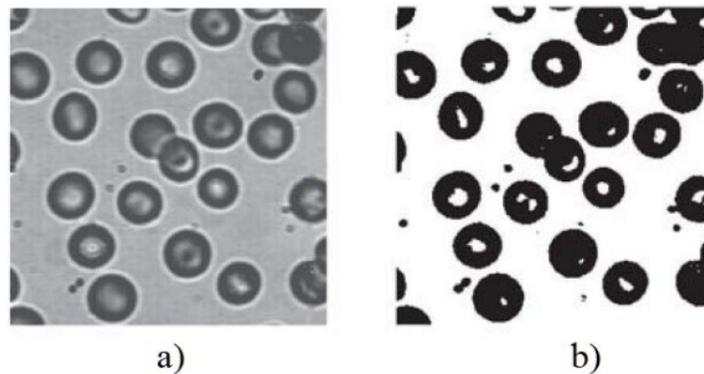


Figura 3.42. Ejemplo de Segmentación. a) Imagen original, b) Imagen Segmentada [Ma, 2010]

La segmentación por detección de bordes, generalmente se realiza por métodos basados en operadores locales sustentados en aproximaciones de la primera y segunda derivada, lo que requiere de cálculos matemáticos laboriosos. Entre las técnicas que se han utilizado para dar solución al problema de segmentación, el más simple y efectivo es el basado en la determinación del umbral del nivel de gris, pero es muy difícil seleccionar un umbral apropiado [Ma, 2010].

En este trabajo se emplea la Red Neuronal de Intersección Cortical ICM, como un método alternativo para dar solución al problema de segmentación de imágenes. Su procesamiento paralelo, y debido a que es un paradigma cercano al modelo biológico, la hacen adaptarse de manera natural al procesamiento de imágenes. Como toda PCNN, la ICM genera una serie de imágenes binarias (debido al efecto auto-onda de la red), una imagen por cada época, que son variaciones de una imagen original. Se ahondará más al respecto en capítulos posteriores, en la parte de experimentación.

Capítulo 4

Modelo Propuesto y Entorno de Experimentación

En este capítulo se muestra el entorno de experimentación, que se conforma de las herramientas utilizadas en este trabajo de tesis, tanto de la Red Neuronal Pulso Acoplada (PCNN): Modelo Neuronal de Intersección Cortical (ICM), como de los algoritmos segmentadores y métricas (criterios) seleccionados para realizar el estudio comparativo, y la experimentación previa realizada para asegurar el buen funcionamiento de la Red Neuronal, y sintonización de parámetros, haciendo uso de la base de datos de imágenes seleccionada.

Dado que la parte central es el estudio basado en segmentación con ICM, primero se aborda el Modelo de Intersección Cortical ICM, como variante de la PCNN, sus fundamentos teóricos que sustentan su funcionalidad computacional, y la manera en que esta Red Neuronal lleva a cabo este proceso. El contenido de este capítulo comprende la fase II y parte de la fase III de la metodología de solución correspondiente a este trabajo (Sección 1.10).

4.1 Modelo de Intersección Cortical (ICM)

El Modelo de Intersección Cortical (ICM), es un caso especial de las Redes Neuronales Pulso Acopladas (PCNN) (Sección 3.11.11), donde la fuerza β del *Linking* es igual a cero, y por lo tanto no hay *Linking*, sólo existe el *Feeding* (Figura 4.1).

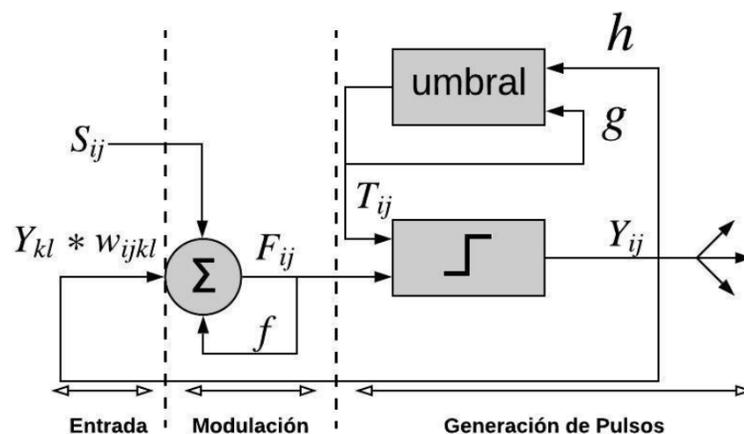


Figura 4.1. Desarrollo del estado interno de una neurona ICM [Ortiz, 2017] [Aguilar, 2019]

Este modelo intenta minimizar el costo computacional, pero mantiene la efectividad del modelo original cuando se aplica a procesamiento de imágenes. El modelo matemático de ICM se conforma de un sistema mínimo de ecuaciones que consiste en dos osciladores acoplados, un número pequeño de conexiones, y una función no lineal. El sistema de Ecuaciones (4.1) describe el modelo ICM [Lindblad, 2005] [Ma, 2010] [Wang, 2010].

$$F_{ij}[n] = f F_{ij}[n - 1] + \sum_{k,l} W_{ijkl} Y_{kl}[n - 1] + S_{ij} \quad (4.1a)$$

$$T_{ij}[n] = g T_{ij}[n - 1] + h Y_{ij}[n - 1] \quad (4.1b)$$

$$Y_{ij}[n] = \begin{cases} 1 & \text{si } F_{ij}[n] > T_{ij}[n - 1] \\ 0 & \text{En otro caso} \end{cases} \quad (4.1c)$$

El estímulo de la red es S , es decir, la imagen de entrada. El estado de la neurona ahora es F , y la salida es Y , y el estado del umbral dinámico es T . Ambos parámetros f y g deben ser menores que uno, y f debe de ser mayor que g para asegurar que el estado del umbral eventualmente disminuya, y de esta manera la neurona se dispare nuevamente. El parámetro h debe tener un valor alto para que incremente el umbral, justo después de que se dispara la neurona. Las conexiones entre neuronas son emuladas por los pesos sinápticos W .

4.2 Algoritmo ICM

El algoritmo computacional de la Red Neuronal ICM, conlleva una comprensión holística del proceso para su apropiada adecuación al entorno de experimentación. Para esto, es importante tener claro que hay tantas neuronas como pixeles tiene la imagen de entrada, por lo tanto, las cantidades F_{ij} , S_{ij} , Y_{ij} , T_{ij} representan arreglos matriciales del mismo tamaño que la imagen. Dicho de otra manera: cada *pixel* es procesado por una neurona, por lo que la red ICM, es una red con las neuronas dispuestas en un plano que se corresponde uno a uno con los pixeles de la imagen (Figura 4.2), de forma que, para acceder a cada *pixel*, se debe recorrer la imagen *pixel* por *pixel*, normalizar cada uno de sus valores, e introducirlos a sus neuronas correspondientes para su respectivo procesamiento. Como se dijo antes, esto último corresponde al estímulo S introducido en la red.

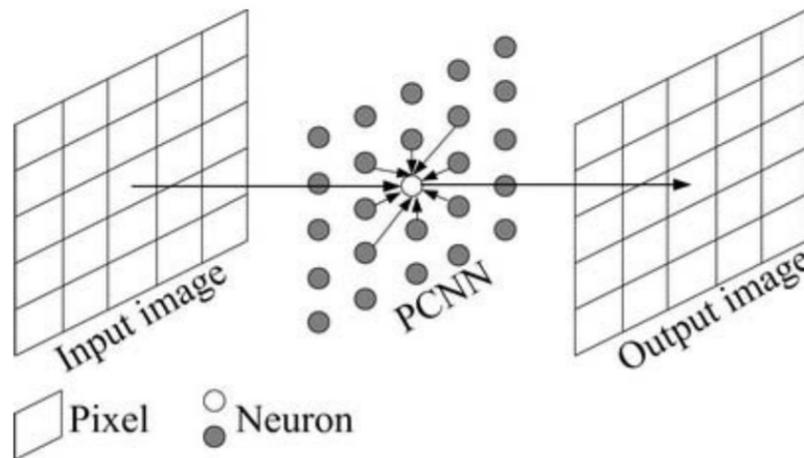


Figura 4.2. Relación uno a uno entre los píxeles de una imagen y neuronas ICM [Xiao-Bo, 2008]

El algoritmo ICM consiste en los pasos siguiente (ver Figura 4.3):

- 1) Alimentar la red ICM con la imagen a procesar.
- 2) Declarar e Inicializar las variables del modelo: F_{ij} , T_{ij} y Y_{ij} así como sus correspondientes variables que representan un estado anterior, dado que el modelo así lo requiere, y lo mismo para los parámetros f , g y h .
- 3) Normalizar los píxeles de la imagen de entrada respecto al valor máximo del rango de valores del pixel, para conformar el estímulo S_{ij} de la Red Neuronal ICM.
- 4) Aplicación de la matriz gaussiana de convolución W_{ijkl} a la matriz Y_{kl} anterior, para emular la interacción de neuronas vecinas en cada pixel de la imagen de entrada.
- 5) Actualizar las variables F_{ij} , Y_{ij} . Si F_{ij} supera a T_{ij} anterior, la neurona se dispara.
- 6) Actualizar T_{ij} .
- 7) Asignar los valores actuales de F_{ij} , Y_{ij} y T_{ij} a sus variables correspondientes del estado anterior, y desnormalizar la salida Y_{ij} que se transformará en la imagen segmentada de esa época.
- 8) Se genera el pulso imagen.

Hay varios conjuntos de valores que sugiere la literatura para los parámetros f , g , h del modelo ICM, mientras cumplan con las condiciones dadas anteriormente. Normalmente se proponen algunos conjuntos de valores, por ejemplo, $\{0.9, 0.8, 20\}$ y $\{0.4, 0.34, 20\}$ para f, g, h respetivamente. En este trabajo se utilizó el primer conjunto de

valores por ser éstos los más empleados en la literatura especializada, aunque se experimentó con diversos conjuntos de valores para analizar el efecto en la segmentación, debido al cambio del valor de los parámetros de la red.

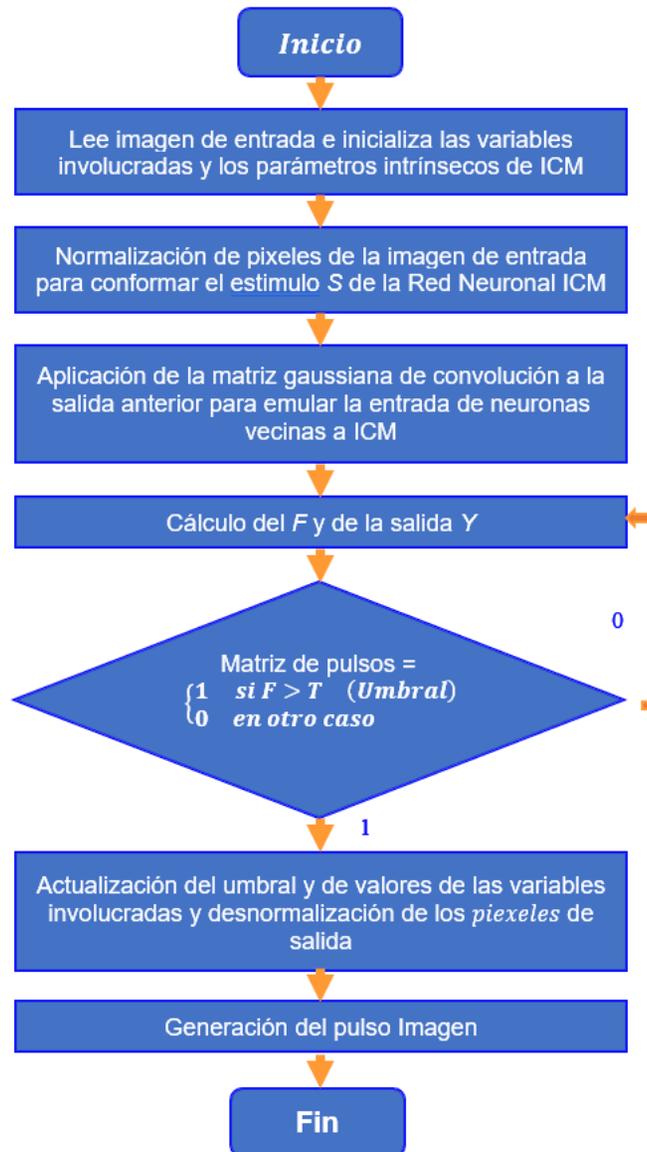


Figura 4.3. Diagrama de flujo del algoritmo ICM

La convolución, *kernel* o máscara gaussiana W utilizada para emular la interacción de las neuronas vecinas, es una matriz de 3×3 con valores $\{\{0.5, 1, 0.5\}, \{1, 0, 1\}, \{0.5, 1, 0.5\}\}$.

4.3 Experimentación preliminar

Se utilizaron diversas imágenes encontradas en la literatura de Visión Artificial (VA) para definir los casos de prueba y validación, que sirvieran como indicadores del proceso adecuado de segmentación de la Red (ver Sección 1.6). En la Figura 4.4 se muestran 9 de las cuarenta imágenes segmentadas mediante ICM de la imagen clásica “Lena” dentro del ámbito de Visión Artificial, correspondiente a 40 épocas. La Red ICM, genera un pulso-imagen por época.



Figura 4.4. Segmentación experimental con ICM. Imagen JPG de Lena en escala de grises (225x225 píxeles)

4.4 Segmentación con ICM

ICM genera una serie de imágenes binarias (una imagen por cada época), que son variaciones de una imagen original en tonos de gris y que son resultado del efecto "auto onda", característico de las Redes Neuronales Pulso Acopladas (PCNN), ver Figura 4.5.

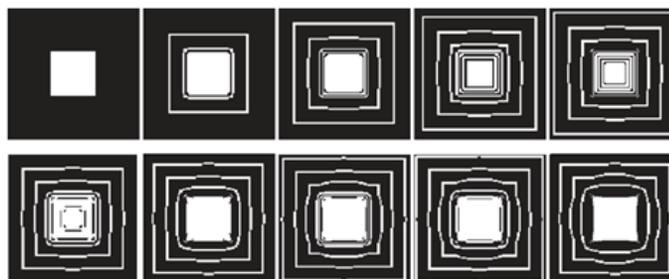


Figura 4.5. Salidas de una Red Pulsante para nueve épocas (efecto “auto onda”) [Ma, 2010]

Cada pulso-imagen con la selección apropiada de parámetros, puede ser pensada como una imagen segmentada de la original, pero ¿cómo lo hace la ICM? Se puede analizar de manera breve (ver Sección 3.11.11). En una neurona que recibe el estímulo de entrada S (de un pixel de la imagen), su actividad interna U ($U = F$ para ICM) aumenta hasta que supera el umbral T . En ese momento la neurona se dispara, lo que provoca que el umbral aumente hasta alcanzar un valor máximo, después de lo cual su valor comienza a decrecer hasta que nuevamente cae por debajo del estado interno de la neurona, provocando nuevamente su disparo, y así sucesivamente. Este proceso da lugar a la naturaleza pulsante de las PCNN (ver Figura 4.6).

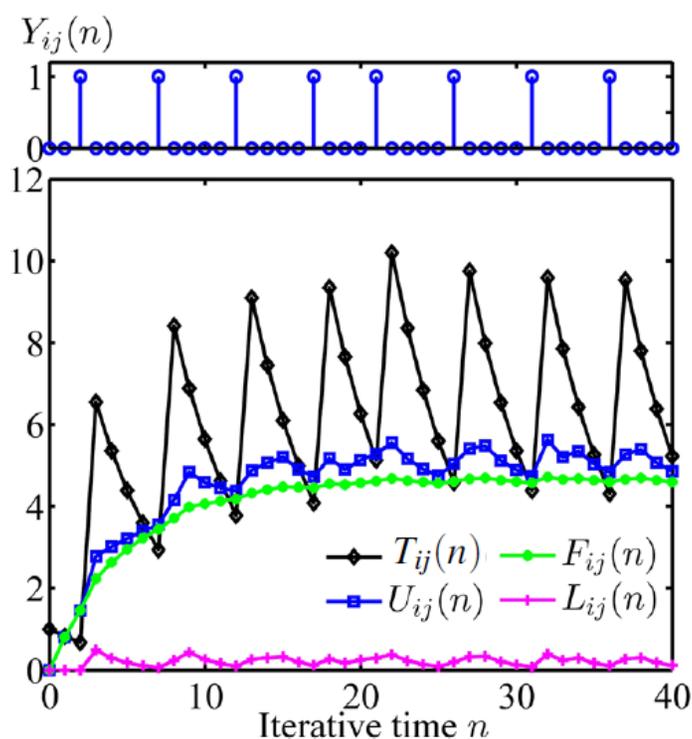


Figura 4.6. Actividad del estado interno de una neurona del tipo PCNN [Zhan, 2016] [Lindblad, 2005]

Cuando una neurona (o grupo de neuronas) se dispara, se produce el efecto de auto onda que emana del perímetro de ese grupo. Las auto ondas se definen como ondas de propagación normales que no se reflejan ni refractan. Este efecto es una de las características que distinguen a la Redes Neuronales Pulso-Acopladas, como la ICM, de otras redes neuronales. La segmentación en la ICM se produce debido a que los grupos de neuronas con estado interno similar tienden a pulsar al unísono, de esta manera, los

bordes y/o regiones se obtienen a medida que el efecto de auto onda se expande de estos segmentos. El aspecto más importante es la calidad inherente en la segmentación de la ICM. La ICM produce bordes finos y limpios en imágenes binarias. La segmentación obtenida se muestra como sólida y uniforme en la salida de la ICM. Los bordes y/o regiones también tienen la misma intensidad en la salida, aunque los bordes de entrada pueden tener un gradiente de intensidades. De esta manera, la ICM es un buen preprocesador para la segmentación, dado que obtiene la información esencial de una imagen (bordes, texturas y regiones) [Lindblad, 2005].

La segmentación mediante el modelo computacional de ICM no tiene un mecanismo de paro, así que debe ser implementada por el usuario. Se puede emplear un cierto número de épocas. Si este número es grande, se tiene el mismo número de imágenes segmentadas, por lo cual surge la pregunta: ¿Cuál de todas estas imágenes es la mejor imagen segmentada? Precisamente este es el trabajo que realizan los criterios o métricas de la Entropía [Weili, 2009], Contraste del Nivel de Gris, Entropía Cruzada y *Overall Merit*, que seleccionan la mejor imagen segmentada como aquella que observa el máximo valor de Entropía o máximo valor del Contraste del Nivel de Gris, o el valor mínimo de Entropía Cruzada (ver el punto 6 de la Sección 1.8) [Ma, 2010].

En este trabajo se planteó el objetivo de implementar y experimentar con la variante de la PCNN llamado: Modelo de Intersección Cortical (ICM) para la segmentación de imágenes digitales del cerebro humano, evaluado con los criterios o métricas de la Entropía (H), Contraste del Nivel de Gris (GC), Entropía Cruzada (CE), y *Overall Merit*, y realizar una comparación con los métodos de segmentación: Canny, Sobel, *Linear Spectral Clustering* y *Watershed*. Los dos primeros son métodos clásicos de detección de bordes [Canny, 1986][Sobel, 2014] y/o regiones, el tercero y cuarto realizan segmentación del tipo superpixel (ver el punto seis de la Sección 1.8). Para este propósito (Sección 4.5), se utilizaron Imágenes Digitales de Resonancia Magnética (MRI) [BrainWeb SBD], con las cuales se alimentó en forma consecutiva la Red Neuronal ICM, iterando un número de 40 épocas.

4.5 Base de datos de Imágenes de Resonancia Magnética (MRI)

La base de datos de imágenes utilizado en este trabajo es un banco de Imágenes de Resonancia Magnética (MRI) del cerebro humano encontrado en la *Web*, llamado

BrainWeb: Simulated Brain Database [BrainWeb SBD], que contiene imágenes realistas producidas por un simulador Imágenes de Resonancia Magnética (MRI) cerebral basado en dos modelos anatómicos: *Normal* (que se encuentra en la *Normal Brain Database*) y *MS* (que se encuentra en la *MS Lesión Brain Database*), para los cuales hay simulaciones tridimensionales completas utilizando tres secuencias ponderadas (Figura 4.7) llamadas T1, T2 y PD (*Proton Density*).

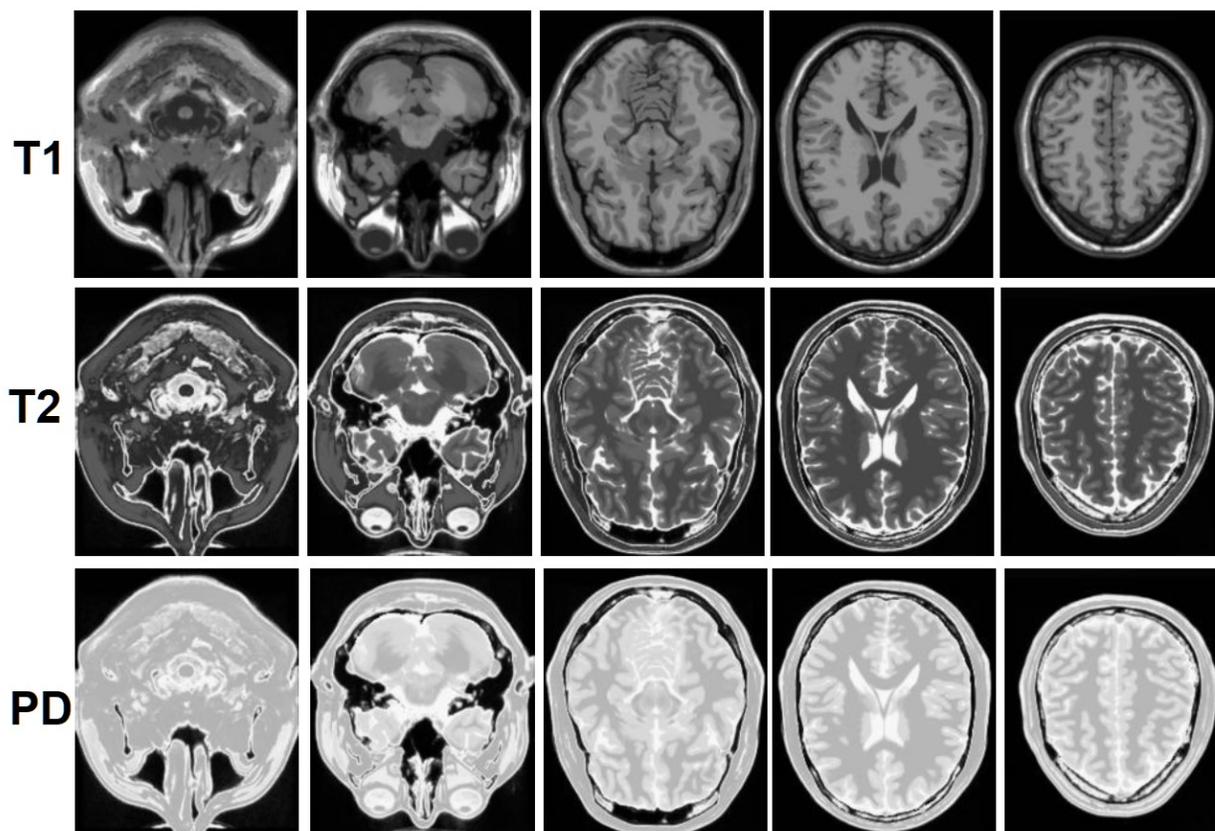


Figura 4.7. Muestras de imágenes de las secuencias ponderadas T1, T2 y PD (*Proton Density*) [Aguilar, 2028] [*BrainWeb SBD*]

Para las tres secuencias mencionadas hay diversidad de espesores en cada corte, con diferentes niveles de ruido e intensidad no uniforme, y tres vistas disponibles: transversal, sagital y coronal. Este estudio está disponible en la red para que la comunidad que hace uso de neuroimágenes pueda utilizarlas para evaluar el rendimiento de los métodos de análisis de imágenes.

En este trabajo se utiliza la modalidad T1 de imágenes cerebrales, en escala de grises, de 181x217 píxeles de ancho y largo respectivamente, formato JPG, Normal, sin

ruido, ni anomalías, y el espesor por defecto. Los cortes en esta modalidad corresponden a un estudio de un sólo cerebro, en la cual, las imágenes cerebrales van cambiando gradualmente. (ver puntos 2 y 3 de la Sección 1.8).

4.6. Métricas Aplicadas

En este apartado se hace una descripción de los criterios o métricas utilizadas en el estudio comparativo: Entropía (H), Contraste del Nivel de Gris (GC), Entropía Cruzada (CE) y Overall Merit (OM) (Sección 1.8).

La palabra “métrica” (en inglés: *metric* o *measure*), en un contexto de procesamiento de imágenes, es un concepto huidizo, al que se elude su definición en artículos y libros investigados, y sólo se refieren a las métricas sin definir las directamente, como “descripción de características generales, que a menudo se utilizan para imágenes completas y regiones de imágenes” [Krig, 2016]. Este mismo autor resalta las métricas para textura de imágenes, y entre ellas considera la Entropía de Shannon como una métrica de textura, en particular le llama “Entropía de borde”. Define la textura como una estructura y patrón común dentro de regiones, las cuales se diferencian en función de la homogeneidad de la textura, que funciona bien como método para la segmentación de regiones, además, dichos métodos, se pueden diseñar simplemente analizando la estructura de bordes de las regiones en una imagen. En un estudio sobre superpíxeles, [Liu M-Y, 2001] aplica la entropía como un componente que favorece grupos (*clusters*) homogéneos y compactos. Yide Ma y colaboradores la aplican en muchos de sus trabajos con PCNN, al igual que la entropía cruzada, ver por ejemplo [Wang, 2010] [Ma, 2010] [Ma, 2004] [Gao, 2018].

La evaluación de la calidad de las segmentaciones es un proceso importante en el procesamiento de imágenes, especialmente en el ámbito médico. Se han utilizado muchas métricas de evaluación para evaluar la segmentación, sin embargo, no existe una manera formal de elegir las métricas más adecuadas para una tarea de segmentación en particular. Se han introducido muchas métricas de evaluación para la segmentación de imágenes, dado que la mayoría de los investigadores eligen las métricas de evaluación de forma arbitraria o según su popularidad [Taha, 2014]. La mejor evaluación de la calidad de segmentación de imágenes se logra mediante la

comparación respecto a su *ground truth*, desafortunadamente, no siempre se cuenta con esa referencia y no existe *ground truth* o estándar dorado para el análisis de datos adquiridos en vivo [Brainweb SBD].

Al parecer, la línea divisoria entre las palabras criterio y métrica es muy tenue, y depende del contexto y aplicación, y quien utilice esos conceptos, dado que muchas veces se aplican de manera indistinta. La palabra “métrica” según lo investigado, significa medir alguna característica de un objeto, que a final de cuentas es una medición de comparación.

4.6.1. Entropía (H)

Según Du-Yih Tsai (2008), la entropía de Shannon es una medida cuantitativa de la información transmitida por una imagen. La calidad de la imagen se puede comparar cuantitativamente cuando se conoce la información transmitida o proporcionada por las imágenes. Desde el punto de vista de la medición física, cuanto más información se transmite, mejor es la calidad de la imagen (aunque según [Gao, 2018] se debe tener cuidado en su uso, en el aspecto configuracional de la imagen). En el estudio que realiza junto con sus colaboradores, presenta un método simple y directo para evaluar sintéticamente imágenes radiográficas digitales, mediante un sólo parámetro en términos de entropía de Shannon (entropía de la información). Su método propuesto (basado en entropía) se considera una alternativa a las métricas disponibles actualmente para la evaluación de la calidad de la imagen [Tsai, 2008]. Por su parte, Kurmasha [Kurmasha, 2017], realiza un trabajo sobre Mejora de las medidas de calidad de imagen basadas en bordes utilizando entropía como métrica.

La Entropía es una propiedad estadística que refleja la cantidad de información contenida en una imagen, y está dada por:

$$H(X) = - \sum_{i=1}^n P(x_i) \log_2 P(x_i) \quad (4.2a)$$

donde X denota el *pixel* de la imagen con n posibles niveles de gris $\{x_1, x_2, \dots, x_i, \dots, x_n\}$, y $P(x_i)$ es la proporción de pixeles con un valor de nivel de gris x_i [Gao, 2018]. En el caso de sólo dos estados 1 y 0, la entropía está dada como:

$$H(S) = - p_1 \log_2 p_1 - p_0 \log_2 p_0 \quad (4.2b)$$

donde p_1 y p_0 son las probabilidades de aparición de 1's (unos), y 0's (ceros) en la imagen segmentada, respectivamente [Ma, 2011].

Para una Entropía máxima, hay balance en la probabilidad de aparición entre estos dos valores, por lo tanto, una entropía máxima, revelará el mejor umbral que seleccionará la mejor imagen segmentada.

En la Figura 4.8, se grafican los valores de probabilidades entre cero y uno contra los valores de entropía utilizando logaritmos de diferentes bases.

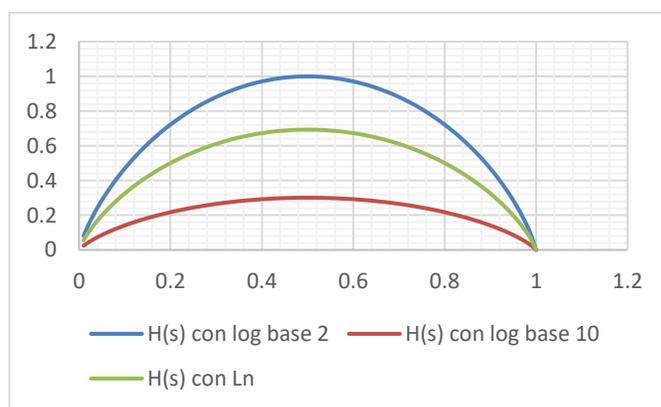


Figura 4.8. Comparación de las gráficas de Entropía utilizando logaritmos de diferentes bases

Se puede observar que la función Entropía tiene un comportamiento simétrico y alcanza su máximo para una probabilidad de 0.5. Los valores de entropía están entre 0 y 1, y su máximo depende de la base del logaritmo que se esté empleando. En este trabajo se utilizan logaritmos de base 2.

Se puede decir que el sistema es la imagen segmentada, la cual contiene dos estados posibles, que son 0 o 1 para cada píxel. Como la probabilidad de aparición de un 1 es p_1 y la de un 0 es p_0 , entonces $p_1 + p_0 = 1$, o también $p_0 = 1 - p_1$ por lo tanto, la ecuación de entropía se puede escribir como:

$$H(S) = -p_1 \ln p_1 - (1 - p_1) \ln(1 - p_1) \quad (4.3)$$

Es decir, en el caso de imágenes binarias, las probabilidades de aparición de 0's y 1's son complementarias, por esta razón, por ejemplo, la entropía para una probabilidad

de 0.25 es igual a la entropía para una probabilidad de 0.75, lo cual se refleja en la gráfica de entropía. El eje de simetría de la gráfica coincide para una probabilidad de 0.5, y es donde la función entropía alcanza su máximo. Alrededor del eje de simetría las probabilidades de aparición de 1's y 0's son muy parecidas, y por lo tanto es igualmente probable la aparición de un 1 o un 0. Se puede decir que, para una entropía máxima, hay homogeneidad en la cantidad de estos dos valores. En otras palabras, la cantidad de pixeles blancos y la cantidad de pixeles negros es muy parecida, y hay balance entre estos dos valores.

4.6.2. Contraste del Nivel de Gris (GC)

La métrica del Contraste en el Nivel de Gris GC (Gray-level Contrast Measure) nos dice que en una imagen segmentada $f(x, y)$ dada en nivel de gris, que consiste en objeto y fondo con promedios f_o y f_b respectivamente, una Medida del Contraste del Nivel de Gris puede calcularse mediante [Ma, 2010]:

$$GC = |f_o - f_b| / (f_o + f_b) \quad (4.4)$$

4.6.3. Entropía Cruzada (CE)

El concepto de Entropía en computación se utiliza siempre en el campo del procesamiento de imágenes, de acuerdo con las propiedades de los datos de la imagen. Las diferencias de contenido de información entre dos distribuciones de probabilidades se miden mediante la Entropía Cruzada, que es una función cóncava hacia arriba. Si se aplica el criterio de Mínima Entropía Cruzada a la segmentación de umbral, en términos generales, se refiere a buscar el umbral, que puede minimizar el contenido de la información antes y después de la segmentación. En este trabajo se aplica la Entropía Cruzada en la selección de la mejor imagen segmentada por ICM [Ma, 2004].

La aplicación del criterio de mínima entropía cruzada en la técnica de segmentación de imágenes hace que la discrepancia del contenido de la información entre la imagen segmentada y la imagen original sea mínima.

De manera formal, el principio de Mínima Entropía Cruzada es utilizado en segmentación de imágenes para buscar el umbral que corresponde a la mínima

diferencia de información entre las dos imágenes, antes y después de la segmentación [Ma, 2010].

Para dos distribuciones de probabilidad $P = \{p_1, p_2, \dots, p_N\}$ y $Q = \{q_1, q_2, \dots, q_N\}$ su Entropía Cruzada se define como:

$$D(P, Q) = \sum_{i=1}^n p_i \cdot \ln \frac{p_i}{q_i} + \sum_{i=1}^n q_i \cdot \ln \frac{q_i}{p_i} \quad (4.5a)$$

En segmentación de imágenes, P y Q representan la imagen original y la segmentada respectivamente.

Para una imagen segmentada con sólo dos niveles de gris, la Entropía Cruzada está dada como:

$$CE = p \ln \frac{p}{q} + q \ln \frac{q}{p} \quad (4.5b)$$

Donde p y q son las probabilidades de aparición de “1’s”, y “0’s” respectivamente, en la imagen segmentada.

4.6.4. Overall Merit (OM)

Para **evaluar** el **rendimiento** de las **métricas anteriores** de manera **exhaustiva**, se sugiere [MA, 2003] la medida de evaluación al **Mérito General u Overall Merit (OM)**.

$$OM = (H + GC + (1 - CE))/3 \quad (4.6)$$

Donde H, GC y CE son los valores correspondientes obtenidos en cada caso al aplicar las métricas de la Entropía, Nivel de Gris y Entropía Cruzada respectivamente.

4.7. Segmentadores seleccionados

Para realizar el estudio comparativo se utilizaron los segmentadores: *Canny*, *Sobel*, *Watershed* y *Linear Spectral Clustering (LSC)*. Se utilizó OpenCV como apoyo para el procesamiento de imágenes, C++ como lenguaje de programación, y Visual Studio como entorno de desarrollo (Sección 1.8).

4.7.1. Canny

El algoritmo del segmentador *Canny* [Canny, 1986], se realiza en 5 fases. En la primera fase “Supresión de ruido”, se aplica un *kernel* gaussiano de 5×5 .

$$K = \frac{1}{159} \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 15 & 4 & 2 \end{bmatrix} \quad (4.7)$$

En la fase 2, se aplican máscaras de convolución en direcciones x , y , para calcular la intensidad y dirección del gradiente

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \quad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (4.8)$$

$$G = \sqrt{G_x^2 + G_y^2}, \quad \theta = \tan^{-1}\left(\frac{G_y}{G_x}\right) \quad (4.9)$$

En la fase 3, se aplica un criterio llamado: “No aplicación de Supresión Máxima” que elimina pixeles que no sean parte del borde, quedando sólo líneas finas.

En la fase 4, llamada Histéresis, se aplican las condiciones para que un pixel forme parte de un borde, de acuerdo a la ubicación del valor del gradiente del pixel, en tres de los intervalos separadas por dos umbrales, un umbral superior y uno inferior.

Se utilizó el segmentador *Canny* de OpenCV para la segmentación de las imágenes médicas del cerebro humano, y posteriormente se aplicó a cada imagen las métricas de la Entropía (H), el Contraste del Nivel de Gris (GC) y Entropía Cruzada (CE) con la finalidad de realizar una comparación contra las imágenes segmentadas mediante ICM. Se reafirmo el resultado anterior con la métrica Overall Merit (OM). Se utilizó la imagen dada por defecto en el detector de bordes Canny de OpenCV.

4.7.2. Sobel

Sobel es un operador de diferenciación discreta [Sobel, 2014] (Realmente Sobel desarrollo su método en 1968, pero no hizo una publicación formal, y sólo hasta el 2014 publico unas memorias acerca de su aportación). Calcula una aproximación del gradiente de la función de intensidad de la imagen, y combina el suavizado y la diferenciación gaussianos.

El procedimiento consiste en el cálculo de las derivadas en las direcciones x , y , que computan los cambios de intensidad de la imagen en esas direcciones, aproximando las derivadas mediante la convolución de la imagen, con un *kernel* de tamaño impar, que en el caso de una ventana de 3×3 , los cambios en intensidad en direcciones x , y son:

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} * I \quad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & 0 & +1 \end{bmatrix} * I \quad (4.10)$$

De esta manera, los cambios en intensidad en cada punto de la imagen se calculan con una aproximación del gradiente en ese punto combinando los dos resultados anteriores:

$$G = \sqrt{G_x^2 + G_y^2} \quad (4.11)$$

Se utilizó el segmentador Sobel de OpenCV para la segmentación de las imágenes digitales del cerebro humano, y posteriormente se aplicó a cada imagen las métricas de la Entropía (H), el Contraste del Nivel de Gris (GC) y Entropía Cruzada (CE) con la finalidad de realizar una comparación contra las imágenes segmentadas mediante ICM. Se reafirmo el resultado anterior con la métrica Overall Merit (OM). Se utilizó la imagen dada por defecto en el detector de bordes Sobel de OpenCV.

4.7.3. Linear Spectral Clustering (LSC)

El agrupamiento espectral lineal (*Linear Spectral Clustering LSC*), se constituye como una alternativa en la segmentación mediante superpíxeles, que es una técnica de preprocesamiento de imágenes que se utiliza en muchas aplicaciones en Visión Artificial, porque proporciona una representación de imagen concisa, al agrupar píxeles en pequeños grupos perceptualmente significativos que se adhieren bien a los límites del objeto [Li & Chen, 2015]. Este algoritmo de segmentación se sustenta en las propiedades de segmentación de superpíxeles que son generalmente deseable: 1) Adherencia a los límites del objeto. 2) Cada superpíxel no debe superponerse con varios objetos. 3) Baja complejidad en sí misma. 4) La información de imagen global que es importante para la cognición de la visión humana debe considerarse de manera apropiada [Stutz, 2017].

El algoritmo de segmentación de superpíxeles LSC se fundamenta en la investigación de la relación entre dos funciones objetivo, llamadas funciones de Cortes Normales (F_{Ncuts}) y K -means Ponderado (F_{k-m}), dado que, la optimización de estas dos funciones objetivo es equivalente, si se da la similitud entre dos puntos en el espacio de entrada, que es igual al producto interno ponderado entre los dos vectores correspondientes en un espacio de características de alta dimensión de diseño elaborado. Además, al limitar aún más el espacio de búsqueda del K -means ponderado, LSC logra una complejidad lineal al tiempo que conserva la alta calidad de los superpíxeles generados. El espacio de entrada se forma de puntos de datos o píxeles.

En el agrupamiento de K -means ponderado, a cada punto de datos se le asigna un peso w , se fija el número K de *clusters* o grupos cada uno con un centro definido, y se pone énfasis en el k -ésimo *cluster*. Se determina una función ϕ que asigna puntos de datos a un espacio de características de mayor dimensión para mejorar la separabilidad lineal. La función objetivo del K -means ponderado (F_{k-m}) depende de los pesos de los puntos de datos, de la función de asignación al espacio de alta dimensión ϕ , y del centro del *cluster*. F_{k-m} se puede minimizar de manera iterativa y eficiente. En cortes normalizados, cada punto de datos corresponde a un nodo en un gráfico $G = (V; E; W)$ en el que V es el conjunto de todos los nodos; E es el conjunto de aristas; y W es una función que caracteriza la similitud entre puntos de datos, que en este caso es una función que se utiliza para medir la similitud de color y otra para medir la proximidad del espacio. El *criterio* de cortes normalizados consiste en maximizar la función objetivo F_{Ncuts} , que depende de la similitud entre pares de puntos de datos. En base a la demostración de Dhillon [Dhillon, 2007], la conexión entre el agrupamiento de K -means ponderado y los cortes normalizados se puede reescribir como la optimización de F_{Ncuts} y F_{k-m} como el mismo problema de maximización de trazas de una matriz.

Bajo esta formulación, la convergencia de la minimización iterativa de F_{k-m} puede garantizarse sólo cuando la matriz del Kernel es definida positiva. Sin embargo, esto no siempre se puede garantizar. Para resolver este problema y revelar aún más la relación entre F_{Ncuts} y F_{k-m} , se formula un corolario que dice que la optimización de las funciones objetivo del K -means ponderado y la función de los cortes normalizados son matemáticamente equivalentes si se cumplen dos criterios matemáticos: 1) Que el

producto interno ponderado de dos vectores en el espacio de características de alta dimensión sea a igual a la similitud entre los dos puntos correspondientes en el espacio de entrada. 2) Que el peso de cada punto en el *clustering* de *K-means* ponderado sea igual al peso total de los bordes que conectan el nodo correspondiente a todos los demás nodos en la función de cortes normalizados.

La prueba del corolario queda demostrada al construir cuidadosamente el espacio de características de alta dimensión definida por ϕ , el resultado de la partición de los cortes normalizados debe ser idéntico al de la agrupación *K-means* ponderado en sus puntos óptimos. Esta conclusión sirve de base del algoritmo LSC.

Para encontrar una forma adecuada de la función de similitud primero se investiga la medición de similitud de píxeles basada en la distancia euclidiana. Cada píxel de una imagen en color se representa mediante un vector de cinco dimensiones formado por los tres valores de sus componentes de color en el espacio de color CIELAB y las coordenadas vertical y horizontal en el plano de la imagen. El rango de cada componente se normaliza linealmente a $[0; 1]$ por simplicidad. Todo esto da el sustento para la demostración matemática del corolario, por lo que se concluye que aplicando directamente *K-means* ponderados en el espacio de características de diez dimensiones obtenido, la función objetivo de los cortes normalizados se puede optimizar de manera eficiente.

El algoritmo de segmentación de superpíxeles LSC, que toma como entrada el número K deseado de superpíxeles, donde los píxeles de la imagen se mapean primero a puntos ponderados en el espacio de características de diez dimensiones, a continuación, se muestrean K píxeles semillas de manera uniforme en toda la imagen con intervalos horizontales y verticales v_x y v_y . Se realizan ligeras alteraciones para evitar píxeles ruidosos y de límite a estas semillas, tal como se utilizan como centros de búsqueda, y sus vectores de características se utilizan como medias ponderadas iniciales de los grupos correspondientes. A continuación, cada píxel se asigna al *cluster* cuya media ponderada está más cerca del vector del píxel, en el espacio de características. Después de la asignación de píxeles, la media ponderada y el centro de búsqueda de cada grupo se actualizarán en consecuencia. Los dos pasos anteriores se

realizan de forma iterativa hasta la convergencia. Los píxeles asignados al mismo grupo forman un superpíxel.

En teoría, el espacio de búsqueda de cada *cluster* debería cubrir la imagen completa para satisfacer el corolario dado, sin embargo, para los superpíxeles, la compacidad local es una prioridad común. Por lo tanto, limitan el espacio de búsqueda de cada grupo al tamaño del píxel, multiplicado por un parámetro (en este caso por simplicidad se escoge el parámetro 2) para equilibrar la compacidad local y la optimización global. Para mejorar la conectividad, se fusionan empíricamente pequeños superpíxeles aislados que tienen menos de una cuarta parte del tamaño del superpíxel esperado, con sus grandes superpíxeles vecinos. Cuando hay más de un candidato para la fusión, eligen el más cercano en el espacio de características de diez dimensiones. Todos estos pasos los resumen en un algoritmo.

El nivel de complejidad computacional del algoritmo LSC se calcula como $O(kN + nz)$, en la que k es el número de iteraciones, z representa el número de pequeños superpíxeles aislados que se fusionarán, n es el número medio de sus vecinos adyacentes, y N el número de píxeles. En la práctica, $nz \ll NI$ y $k = 20$ será suficiente para generar superpíxeles con la calidad avanzada. LSC tiene una complejidad lineal $O(N)$ y se encuentra entre los algoritmos de segmentación de superpíxeles más rápidos [Li & Chen, 2015].

Se utilizó el segmentador *Linear Spectral Clustering* (LSC) de código abierto de OpenCV para la segmentación de las imágenes médicas del cerebro humano, y posteriormente se aplicó a cada imagen las métricas de la Entropía (H), el Contraste del Nivel de Gris (GC) y Entropía Cruzada (CE) con la finalidad de realizar una comparación contra las imágenes segmentadas mediante ICM. Se reafirmo el resultado anterior con la métrica Overall Merit (OM).

4.7.4. Watershed (W)

La segmentación de superpíxeles *Watershed*, es un método basado en regiones que tiene su origen en la morfología matemática [Serra, 1982]. Se pueden encontrar en la literatura, implementaciones del algoritmo *Watershed* controladas por marcadores [Hu, 2015] de código abierto para la segmentación de imágenes, donde se plantea que el

algoritmo *Watershed*, es uno de los algoritmos de segmentación más comunes utilizados en el procesamiento de imágenes médicas y de ciencia de materiales [Kornilov, 2018].

La segmentación de una imagen digital es el proceso de su división en varias regiones inconexas, de modo que los píxeles de cada región tienen características visuales similares, cuyo objetivo es simplificar la representación de una imagen para su posterior análisis, por lo que es fundamental en el reconocimiento y clasificación de patrones, visualización, compresión de imágenes basada en objetos de interés, entre muchas otras [Kornilov, 2018], con diferentes aplicaciones sobre todo en diferentes campos de medicina y biología.

El algoritmo se basa en la representación de una imagen cuyos valores de intensidad de la escala de grises, forman las diversas alturas de un relieve topográfico, compuesto de valles bajos (mínimos), cordilleras de gran altitud (líneas de *watershed*), declives, y mesetas (área con elementos de la misma altura) [Kornilov, 2018] [Hahn, 2005], ver Figura 4.9.

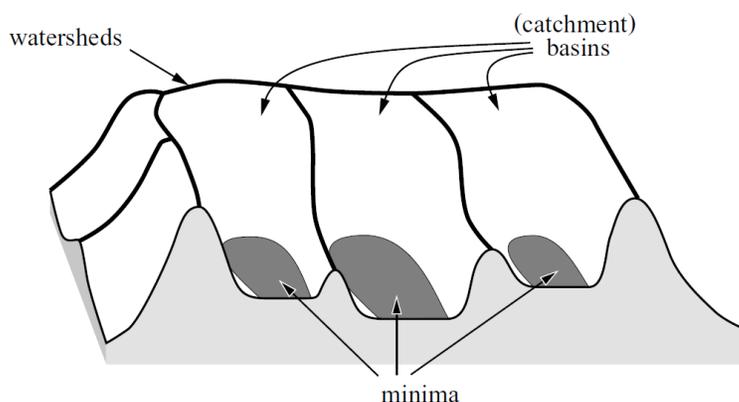


Figura 4.9. Interpretación topográfica de una imagen en la segmentación *Watershed*, con colinas y valles (cuencas de captación) [Hahn, 2005]

La tarea principal del algoritmo es determinar la ubicación de todas las cuencas de captación y/o líneas *watershed*, porque cada cuenca de captación se considera un segmento separado de la imagen (región segmentada), con o sin sus límites. Hay dos enfoques principales para encontrar estas *watershed*: mediante simulación por inundaciones y mediante simulación por lluvias [Kornilov, 2018] [Beucher, 1993].

En el enfoque de *Watershed* por inundación primeramente propuesto por [Soille, 1991] en cada mínimo (el más bajo), "se perforan agujeros", y todo el relieve comienza

a inundarse de agua, llenando gradualmente todas las cuencas de captación. Las *watershed* se construyen en los lugares donde se une el agua de diferentes cuencas. El proceso termina cuando el agua alcanza el pico máximo del relieve, en ese momento, cada cuenca de captación queda cubierta por las líneas *watershed* (Figura 4.10).

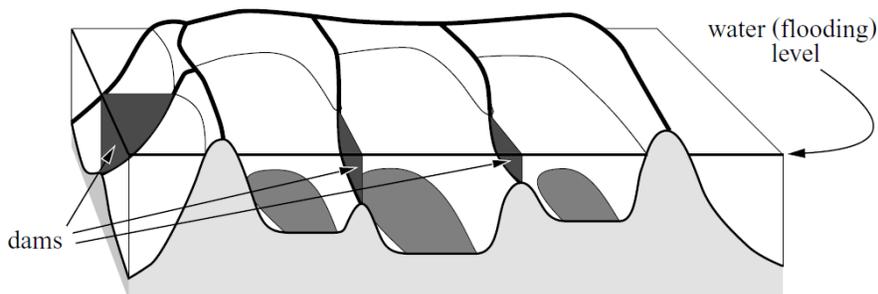


Figura 4.10. En un escenario de inundación, el agua proveniente de cuencas vecinas se fusionaría a niveles de inundación progresiva, se construyen diques o watersheds [Hahn, 2005]

Para simular este proceso se proponen dos algoritmos A y B basados en colas de prioridad.

Pasos del algoritmo Beucher [Kornilov, 2018]:

A1) Localizar mínimos locales en la imagen, y asignar un marcador único.

A2) Simular proceso de inundación con una cola prioridad que consta de H colas, (H valores de gris). Cuando ésta se llena, los elementos de la imagen con el valor h se empujan a la cola correspondiente con el número h.

- a) Rellenar la cola de prioridad con los elementos de mínimos locales de la imagen.
- b) Escanear la cola de prioridad en secuencia de valores de h pequeños a grandes. Seleccionar el elemento de la primera cola no vacía. Si todas las colas de la cola de prioridad están vacías, el algoritmo termina.
- c) Eliminar el elemento seleccionado de la cola y su marcador se propaga a todos los vecinos no marcados.
- d) Colocar vecinos marcados (paso c), en la cola de prioridad.

Ir al paso A2. Este algoritmo no contiene líneas watershed.

Pasos del algoritmo Meyer [Kornilov, 2018];

B1) Similar al paso A1.

B2) Definir cola prioridad. Marcar los elementos colocados en esta cola (marcador adicional).

- a) Marcar elementos que ya tienen un marcador único, con un marcador adicional.
- b) En la cola prioridad, agregar elementos que tienen vecinos marcados. Marcarlos con un marcador adicional.
- c) Similar al paso A2.
- d) Eliminar el elemento seleccionado de la cola. Si todos sus vecinos marcados estaban marcados con el mismo marcador, marcar el elemento en sí con este marcador. Si el elemento seleccionado era vecino de elementos con diferentes marcadores, marcarlos con un marcador especial, lo que significa que es un elemento de la cuenca.
- e) Los vecinos de este elemento que aún no se han marcado con un marcador adicional se colocan en la cola de prioridad.
- f) Ir al paso B2c.

En el enfoque de *Watershed* por simulación de lluvia, la idea básica es que las gotas de lluvia al caer sobre la superficie del relieve de la imagen fluyen por la pendiente más empinada hasta la cuenca correspondiente, esta trayectoria se llama componente de conectividad. Todos los componentes conectados que conducen al mismo valle forman una cuenca de captación. El algoritmo utiliza marcadores para marcar todas las cuencas de captación con sólo cuatro pasadas completas de la imagen como máximo.

El algoritmo clásico C propuesto por Bieniek y Moga [Kornilov, 2018] [Bieniek & Moga, 2000], consta de los siguientes pasos:

C1) Marcar cada elemento de la imagen con la ubicación del elemento adyacente inferior, que tiene el valor más pequeño (generalmente realizado con punteros). Si no hay tales elementos en el vecindario, entonces el actual elemento se marca como un elemento de la meseta.

C2) Eliminación de mesetas no mínimas.

- a) a) Verificar a los vecinos para cada elemento marcado como meseta. Si entre ellos se encuentra uno que no está marcado como meseta y tiene el mismo valor que el elemento en sí, se empuja a este vecino a la cola y se completa la verificación de los vecinos para este elemento.

- b) Mientras la cola de vecinos no está vacía, se remueve los elementos de ella. Se comprueba que sus vecinos estén marcados como meseta. Se marcan con marcadores que apunten a la ubicación del elemento eliminado y se colocan todos en la cola.

C3) Marcar los elementos mínimos de meseta con valores representativos.

- a) Primero, marcar cada elemento que esté marcado, como una meseta, con un marcador que apunte al elemento mismo.
- b) Secuencialmente, se toman los vecinos del elemento actual que ya se han pasado, y tienen el mismo valor. Para el elemento actual y este vecino, se realiza un procedimiento de compresión de ruta, que consiste en recorrer el camino utilizando marcadores como punteros de movimiento, desde el elemento dado hasta el marcado con un marcador apuntando a sí mismo, y luego asignar a cada marcador de los elementos del camino el valor del marcador del elemento finito en él.
- c) C4) Pasada 4. Para cada elemento de la imagen se realiza el procedimiento de compresión de ruta. Se marcan los elementos con marcadores de elemento finito del camino recorrido por el procedimiento de compresión.
- d) El algoritmo termina.

El resultado del algoritmo dado es el mismo que cuando se usa cualquier algoritmo tradicional que no crea líneas divisorias. Al mismo tiempo, no depende del rango de valores posibles de los elementos de la imagen, utiliza estructuras de datos simples y gasta menos tiempo de ejecución que los algoritmos basados en simulación de inundaciones.

Ambos enfoques *Watershed* de simulación por lluvia y por inundación, presentan ventajas y desventajas en diferentes escenarios, por esta razón han surgido algoritmos *Watershed* optimizados [Kornilov, 2018].

Cuando se aplica a imágenes reales, *Watershed* causa un problema de sobresegmentación, debido a que no todos estos mínimos son igualmente importantes para ser el centro de las cuencas de captación, por causas de ruido, fluctuaciones de

brillo, entre otras. Este problema se alivia utilizando la técnica *watershed* controlada por marcadores.

Se utilizó el segmentador *Watershed* (W) de código abierto de OpenCV para la segmentación de las imágenes médicas del cerebro humano, y posteriormente se aplicó a cada imagen las métricas de la Entropía (H), el Contraste del Nivel de Gris (GC) y Entropía Cruzada (CE) con la finalidad de realizar una comparación contra las imágenes segmentadas mediante ICM. Se reafirmo el resultado anterior con la métrica Overall Merit (OM).

4.8. Plataforma de Experimentación

Todos los algoritmos se ejecutaron en una PC *Dell Inspiron 15 series 5000*, memoria *RAM* de 16 GB y unidad de disco duro *Solid State* de 0.5 TB, *SK Hynix SC311* SATA. CPU con un microprocesador Intel *CORE i7* a 2 GHz. Todos los programas se escribieron en el lenguaje de programación C++ y se compilaron en el entorno de desarrollo *Microsoft Visual Studio C ++ 2017* y se ejecutaron en el sistema operativo Windows 10 (64 bits). Se utilizó *OpenCV* como apoyo para el procesado de imágenes.

4.9. Discusión

El entorno de experimentación no sólo toma en cuenta las herramientas utilizadas que forman la plataforma para la concreción de los objetivos de este trabajo, sino que en el transcurso se realiza investigación y la primera experimentación, avanzando paso a paso y preparando el terreno para la parte de resultados. La experimentación comienza desde el momento en que se introducen las primeras imágenes al algoritmo de la ICM (Sección 4.3), y lograr una salida de imagen comparable a resultados encontrados en la literatura de segmentación de imágenes mediante el ajuste de parámetros.

Dentro de la segmentación de imágenes digitales del cerebro humano con ICM, primeramente, se experimentó con las métricas de la Entropía (H) y del Contraste del Nivel de Gris (GC), y con sólo dos imágenes del cerebro humano (MRI) de la base de datos *BrainWeb*. Posteriormente se realizó la misma experimentación, pero con 150 imágenes, procesadas tanto por ICM, como por Canny de OpenCV, de lo cual se ahondará en el siguiente capítulo.

Capítulo 5 Experimentación y Resultados

En este capítulo se muestra el desarrollo paso a paso del proceso de experimentación realizada sobre segmentación de imágenes digitales del cerebro humano, tomadas de la base de datos de Imágenes de Resonancia Magnética (MRI): *BrainWeb: Simulated Brain Database* (ver Sección 4.5), hasta llegar a los resultados finales del estudio comparativo entre la Red Neuronal Pulso Acoplada (PCNN): Modelo Neuronal de Intersección Cortical (ICM), y los algoritmos segmentadores: Canny, Sobel, *Linear Spectral Clustering* (LSC) y *Watershed* (W), bajo las métricas (criterios): Entropía (H), Contraste del Nivel de Gris (GC), Entropía Cruzada (CE) y Overall Merit (OM), (ver Sección 1.6 y 1.8).

En este trabajo se utilizan imágenes digitales del cerebro humano en escala de grises de 181x217 píxeles en formato JPG, de la modalidad T1 de la base de datos *BrainWeb* [*BrainWeb SBD*], ver Sección 1.8.

El contenido de este capítulo comprende la segunda parte de la fase III y la fase IV de la metodología de solución correspondiente a este trabajo (Sección 1.10).

5.1 Segmentación con ICM y Canny

La filosofía con la cual se comenzó a experimentar sobre segmentación en este trabajo se fundamenta en el estudio de la Red Neuronal de Intersección Cortical ICM, como un método alternativo para dar solución al problema de segmentación de imágenes, debido a sus características de procesamiento paralelo y debido a que es un paradigma cercano al modelo biológico [Eckhorn, 1990], lo cual la hacen adaptarse de manera natural al procesamiento de imágenes [Lindblad, 2005] [Ma, 2010].

En cada época, la ICM genera una serie de imágenes binarias, que son variaciones de una imagen original (Sección 4.4), de esta manera, debe implementarse una forma de seleccionar la mejor imagen segmentada de entre las pulso-imágenes en la salida de la ICM. Para realizar una evaluación de la mejor imagen segmentada, se seleccionaron dos criterios de evaluación o métricas: la Métrica del Contraste del Nivel de Gris (GC), y la Entropía (H) [Ma, 2010]. De esta manera, se agrega un paso al

algoritmo, y al diagrama de flujo del algoritmo ICM: “Selección de la imagen de salida de acuerdo con las métricas H y GC” (Sección 4.2) ver Figura 5.1.

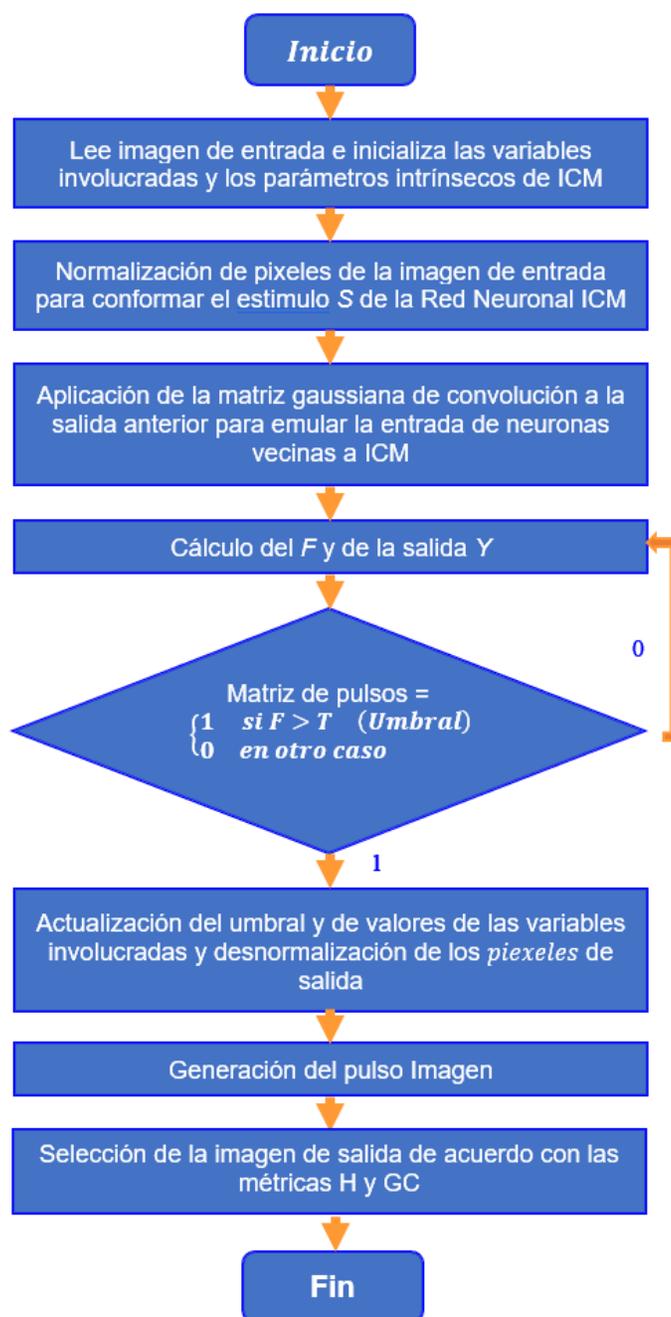


Figura 5.1. Diagrama de flujo del algoritmo ICM con mecanismo de selección de mejor imagen segmentada

Sustentado en lo anterior, se realizaron experimentos utilizando segmentación con ICM y las métricas de la Entropía (H) y del Contraste del Nivel de Gris (GC) para selección

de la mejor imagen segmentada de algunas imágenes del cerebro humano, con la finalidad de sintonizar los parámetros intrínsecos de la red y observar los resultados dados en la salida, para estas dos métricas.

Originalmente se fijaron los valores de los parámetros f, g, h , de ICM como sigue: $f = 0.19$, $g = 0.89$ y $h = 18.2$, y un total de 40 épocas. Se utilizó una imagen digital de Resonancia Magnética (IRM) a la cual se le aplicó la métrica de la Entropía (H). Para el caso de aplicación del Contraste del Nivel de Gris, se fijaron los valores de los parámetros f, g, h , de ICM como sigue: $f = 0.4$, $g = 0.34$ y $h = 20$, y un total de 40 épocas. Se utilizó la misma imagen digital de Resonancia Magnética (IRM).

En la Figura 5.2 se muestra la imagen original y las imágenes segmentadas resultantes, mediante las métricas de la Entropía, y del Contraste del Nivel de Gris obtenidas con ICM, y la imagen segmentada con Canny, respectivamente.

La Figura 5.3 muestra el proceso descrito, así como las gráficas resultantes, en donde los primeros resultados mostraban una mejor evaluación de la imagen segmentada con ICM, respecto de Canny, bajo ambas métricas mencionadas. Se grafica el número de épocas (que determina el número del pulso-imagen) en ambas gráficas, contra los valores que puede tomar la Entropía y el Contraste del Nivel de Gris.

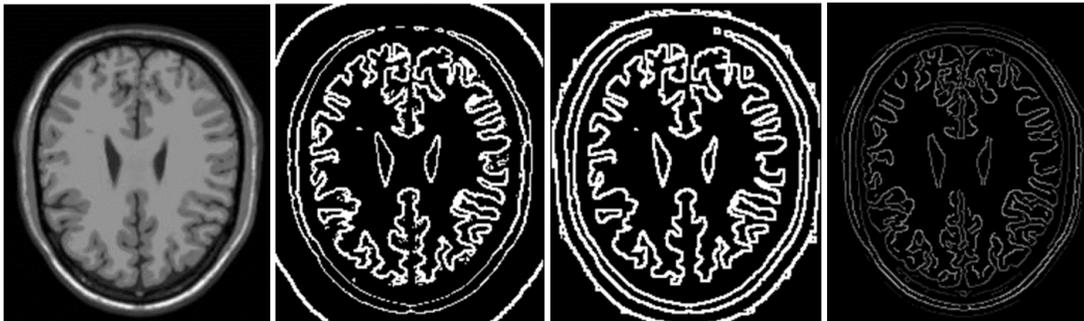


Figura 5.2. De izquierda a derecha: Imagen original, imágenes segmentada mediante ICM, y seleccionadas mediante H y GC respectivamente. Segmentación mediante Canny. En el caso de ICM, los valores máximos obtenidos en ambas métricas fueron: $H = 0.146717$ y la mejor imagen segmentada ocurre en la época 21. $GC = 0.571429$ y ocurre en la época 21

Las observaciones preliminares para los parámetros f, g, h , seleccionados bajo cada métrica respectiva, determinaban que la ICM se comportaba como buena detectoras de bordes, y que ambas métricas son sensibles a cambios en los parámetros

de la ICM, y que, además, la sintonización de parámetros podría determinar la mejor imagen segmentada en bordes, y/o regiones.

Retomando la Figura 5.3, se observa la entrada de una imagen original del cerebro humano, el comportamiento de la Entropía y del Nivel de Gris en sus gráficas respectivas, los valores máximos de ambas métricas para cada imagen segmentada, y donde también se puede observar el mejor desempeño de ICM, en comparación con Canny.

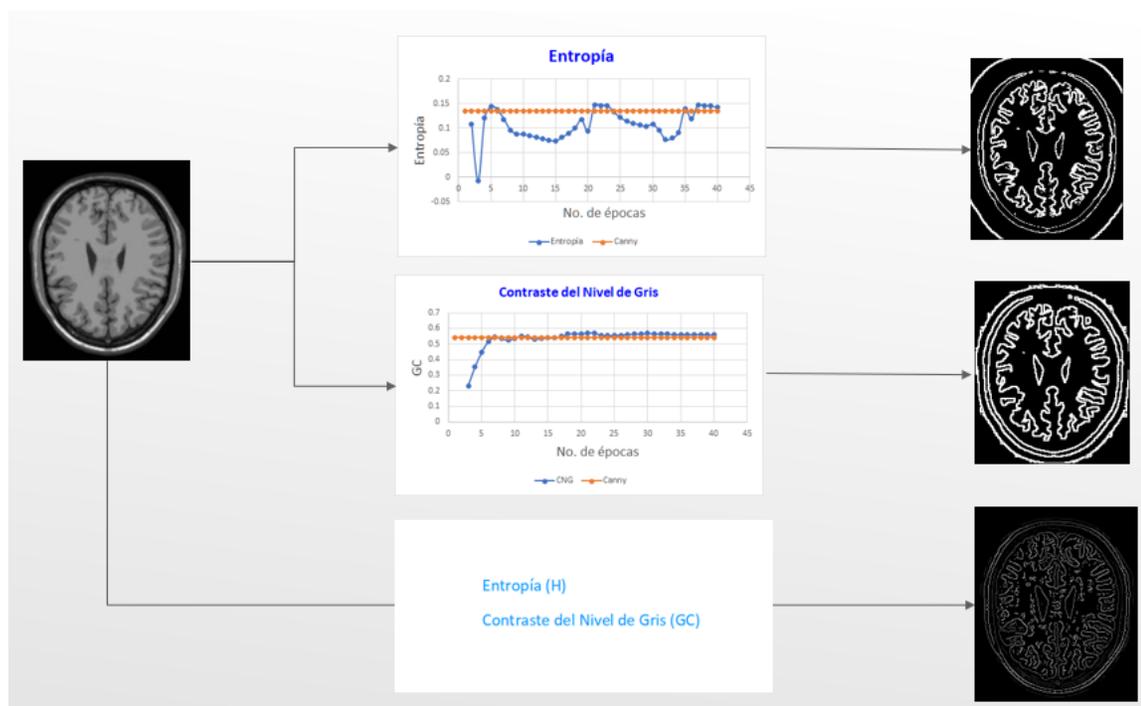


Figura 5.3. Se muestra la entrada de una imagen del cerebro humano a ICM y Canny, con los valores de la H y GC para ambos, así como las imágenes de salida correspondientes

Para dar continuidad a los resultados anteriores, se aumentó el número de imágenes a un total de n imágenes, donde n podría ser 5, 10, o el total de imágenes de la base de datos BrainWeb, para lo cual se modificó el código de ICM, de manera que llamara cada imagen en orden, realizara cuarenta segmentaciones para cada una de ellas, y seleccionara la mejor imagen segmentada mediante las métricas de la Entropía y del Contraste del Nivel de Gris, entregando finalmente, las n imágenes mejor segmentadas. De igual manera se modificó el código del segmentador Canny de OpenCV, para que segmentara n imágenes de la base de datos *BrainWeb* (Figura 5.4)

para la etapa actual de estudio, y aplicarles las métricas de la Entropía y el Contraste del Nivel de Gris.



Figura 5.4. Algunas de las imágenes segmentadas mediante Canny de OpenCV

De esta manera, se procesaron $n = 150$ imágenes del cerebro humano de la base de datos [*BrainWeb* SBD] en la modalidad T1 (Sección 4.5), mediante el detector de bordes Canny con código de Opencv, y mediante segmentación con la Red Neuronal ICM.

En el caso de ICM se utilizaron las métricas de la Entropía y del Contraste del Nivel de Gris para seleccionar la mejor imagen de entre las imágenes segmentadas. De igual manera, en el caso de Canny se aplicaron también ambas métricas de la Entropía y Contraste del Nivel de Gris a las 150 imágenes segmentadas obtenidas por defecto para realizar la comparación contra ICM.

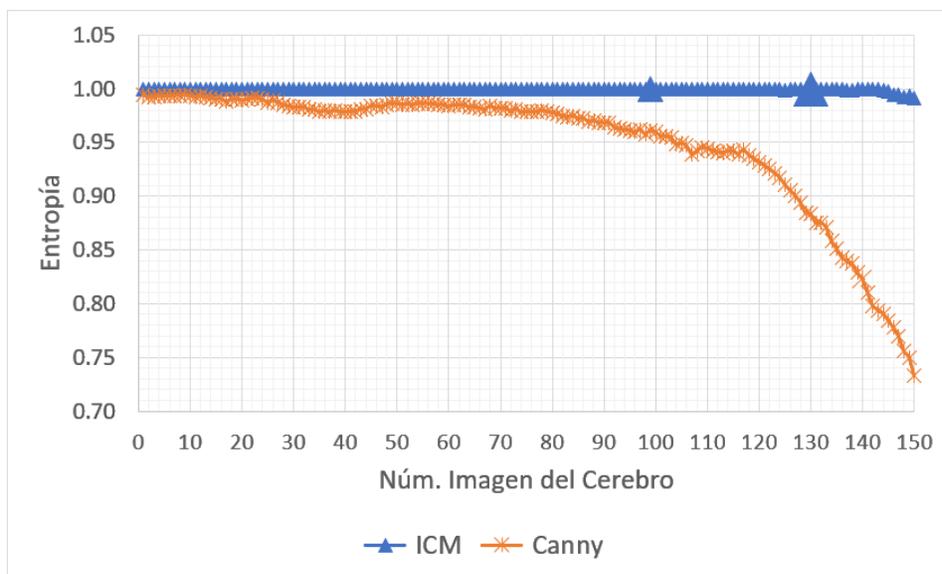


Figura 5.5. Comparación de la Entropía para 150 imágenes aplicando ICM y Canny

En Figuras 5.5 y 5.6 se muestran las gráficas correspondientes a estos resultados. Se observa la comparación de Entropía y del GC para 150 imágenes entre ICM y Canny.

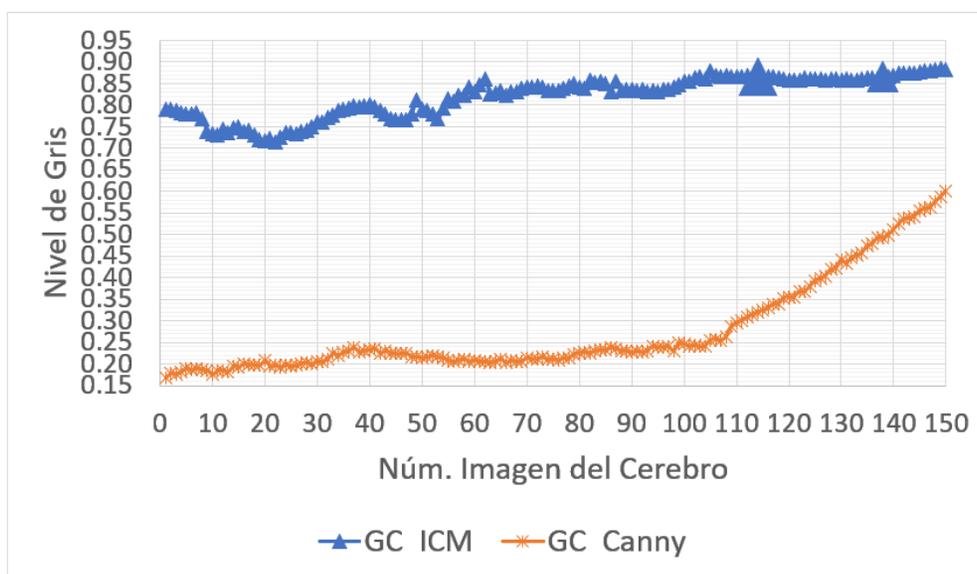


Figura 5.6. Comparación del Contraste del Nivel de Gris para 150 imágenes aplicando ICM y Canny

Se puede observar mejor desempeño de ICM en ambos casos, el cual fue de 30%. Esta estimación se obtuvo promediando la suma de las distancias entre cada pareja de puntos que representan el valor de la Entropía para cada imagen segmentada, correspondiente a ICM y Canny. De igual manera para el caso del Contraste de Nivel de gris, para finalmente obtener un promedio de ambas mediciones.



Figura 5.7. De izquierda a derecha: Imagen original, imágenes segmentada mediante ICM, y seleccionadas mediante H y GC respectivamente. Segmentación mediante Canny. En el caso de ICM, los valores máximos obtenidos en ambas métricas fueron: $H = 0.9999$. $GC = 0.8563$. Para Canny, $H = 0.9559$ y $GC = 0.2417$

En la Figura 5.7 se da un ejemplo del proceso descrito. Se muestra una de las imágenes originales, y las correspondientes imágenes segmentadas mediante ICM utilizando ambas métricas, así como la segmentación mediante Canny.

En la etapa de experimentación anterior, y futuras experimentaciones, la indicación del Dr. Manuel Mejía Lavalle, director de este trabajo de tesis, fue el de ajustarse a los conjuntos de valores que sugiere la literatura para los parámetros f, g, h del modelo ICM.

Normalmente se proponen algunos conjuntos de valores, por ejemplo, $\{0.9, 0.8, 20\}$, $\{0.4, 0.34, 20\}$ para f, g, h respectivamente. En este trabajo se seleccionó el primer conjunto de valores con la utilización de las métricas de la Entropía y el Contraste del Nivel de Gris, por ser éstos los más empleados en la literatura especializada (Sección 4.2). Se ha encontrado que estos parámetros son sensibles a la forma estructural de la ecuación de la métrica, por lo tanto, se tienen que sintonizar los parámetros con las ecuaciones utilizadas, después de lo cual se mantienen fijos.

Tomando en cuenta el aspecto cuantitativo, con las condiciones y finalidad dadas hasta esta etapa del estudio, ICM supera a Canny, utilizando 150 imágenes y las métricas mencionadas. El uso de otra métrica, o aumentando el número de imágenes, podría variar los resultados.

Un análisis cualitativo de los resultados de la segmentación, atendiendo a una percepción visual subjetiva se deja de lado, dando paso a resultados basados en números solamente, es decir, desde una perspectiva cuantitativa, la cual muestra hasta ahora, que ICM se comporta mejor que Canny, bajo las métricas de la Entropía (H) y Contraste del Nivel de Gris (GC), lo cual se le atribuye al procesamiento paralelo de ICM.

5.2 Segmentación ICM bajo la Métrica Entropía Cruzada

Los estudios de segmentación entre ICM y Canny bajo la métrica de máxima Entropía (H) y Contraste del Nivel de Gris (GC), mostraron resultados favorables para ICM, lo cual fue material para trabajo de *poster* y *artículo* (Anexo A y C), de manera que, siguiendo esta línea de trabajo, se realiza el mismo estudio, pero ahora con la métrica (criterio) de Mínima Entropía Cruzada [Ma, 2010].

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y Canny aplicando la métrica de Entropía Cruzada (CE), que selecciona la mejor imagen segmentada, cuyos resultados (Figura 5.8), muestran un mejor desempeño de ICM respecto de Canny.

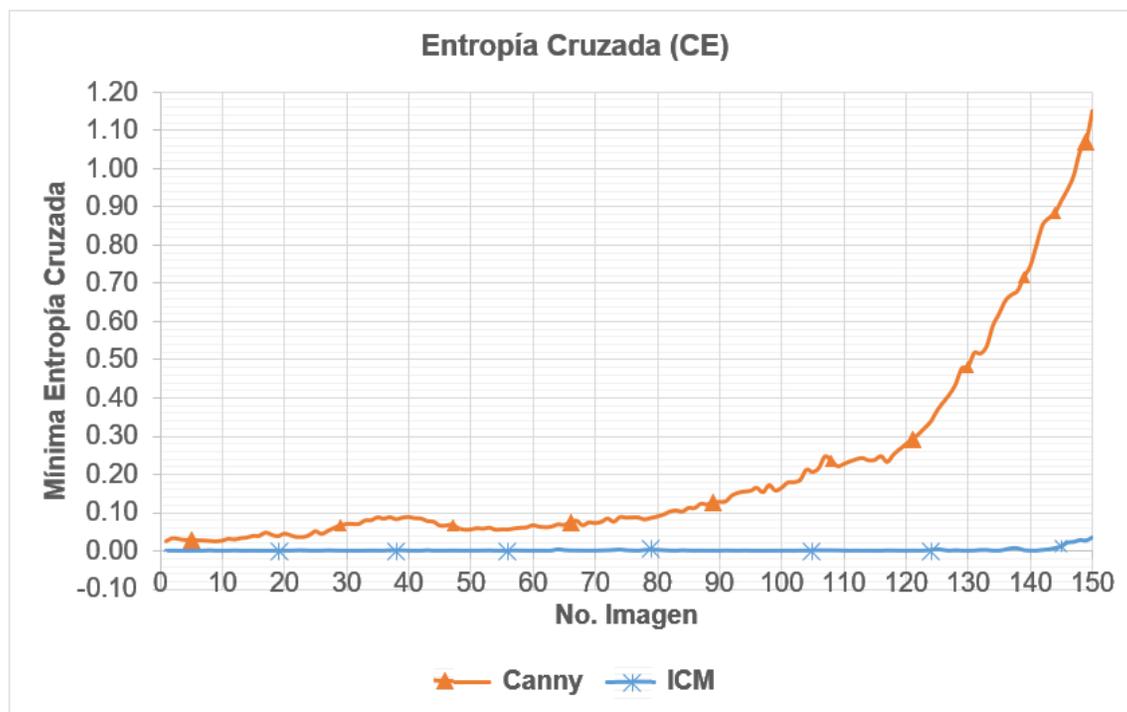


Figura 5.8. Comparación de la Entropía Cruzada para 150 imágenes aplicando segmentación ICM y Canny

De la misma manera como se procedió con Canny, se realizaron segmentaciones de 150 imágenes de la base de datos *BrainWeb*, mediante el segmentador Sobel de OpenCV (Figura 5.9).

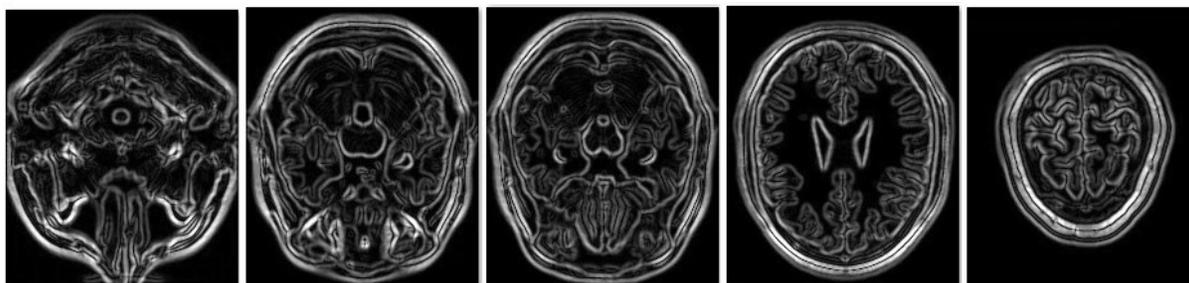


Figura 5.9. Algunas de las imágenes segmentadas mediante Sobel de OpenCV

Lo anterior con la finalidad de realizar la comparación de segmentación entre ICM y Sobel, bajo la métrica de Entropía Cruzada.

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y Sobel aplicando la métrica de Entropía Cruzada (CE), para selección de la mejor imagen segmentada, cuyos resultados (Figura 5.10), muestran un mejor desempeño de ICM respecto de Sobel.

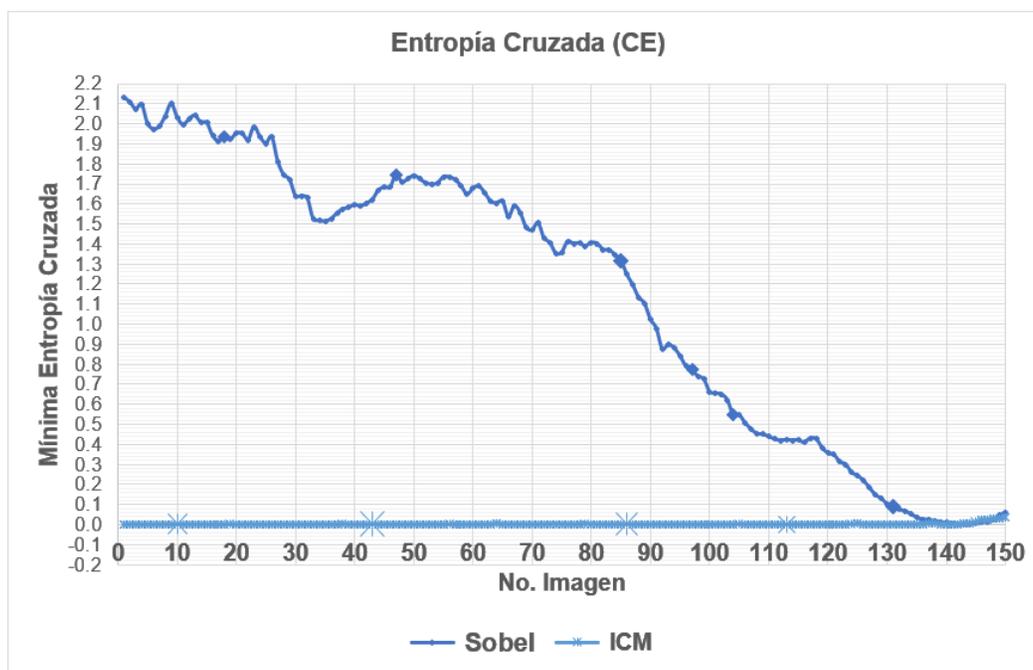


Figura 5.10. Comparación de la Entropía Cruzada para 150 imágenes aplicando segmentación ICM y Sobel

Siguiendo esta línea de experimentación, se realizaron segmentaciones de 150 imágenes de la base de datos *BrainWeb*, mediante el segmentador *Watershed* de código abierto y OpenCV (Figura 5.11).

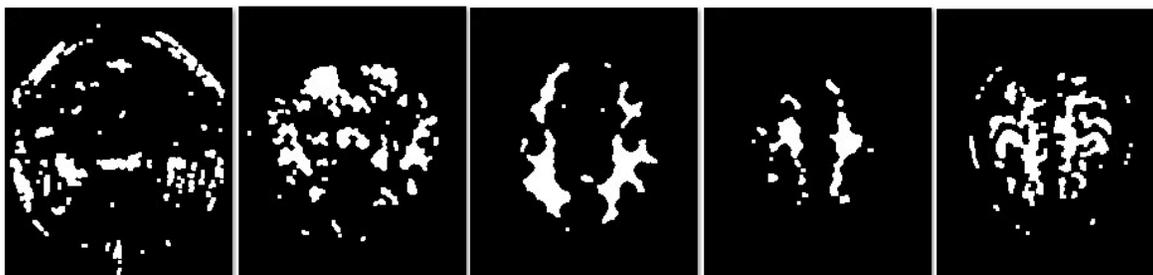


Figura 5.11. Algunas de las imágenes segmentadas mediante *Watershed* de OpenCV

Lo anterior con propósito de realizar la comparación de segmentación entre ICM y el segmentador *Watershed*, bajo la métrica de Entropía Cruzada.

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y *Watershed* aplicando la métrica de Entropía Cruzada (CE), para selección de la mejor imagen segmentada, cuyos resultados (Figura 5.12), muestran un mejor desempeño de ICM respecto de *Watershed*.

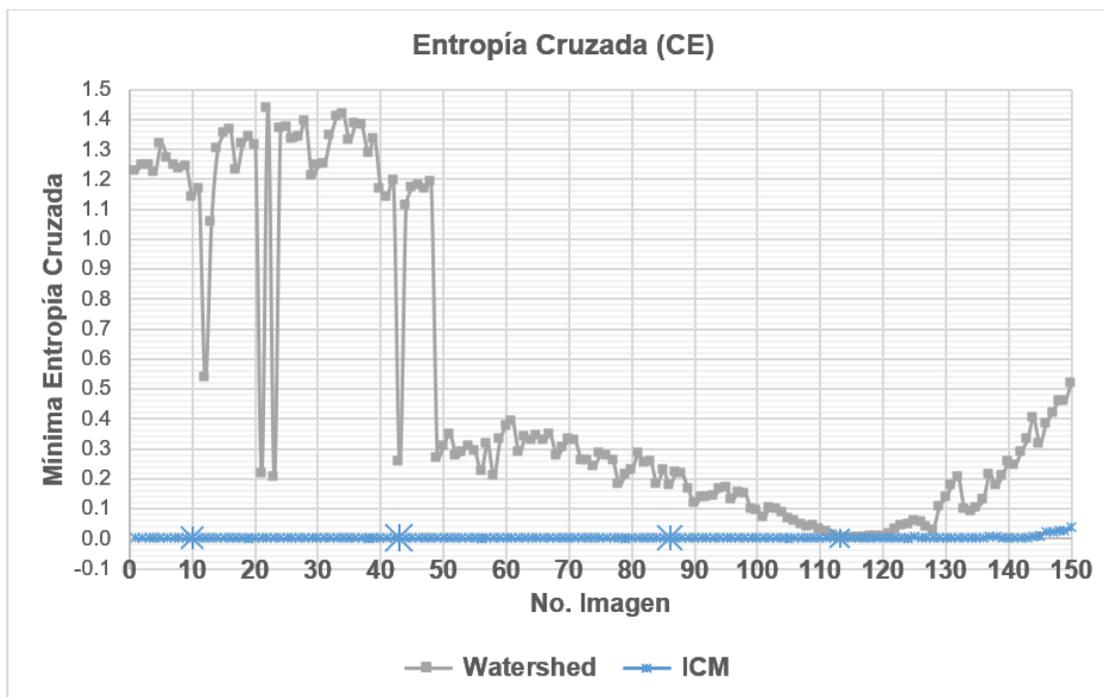


Figura 5.12. Comparación de la Entropía Cruzada para 150 imágenes aplicando segmentación ICM y Watershed

De igual manera, se realizaron segmentaciones de 150 imágenes de la base de datos *BrainWeb*, mediante el segmentador *Linear Spectral Clustering* (LSC) de código abierto y OpenCV (Figura 5.13).

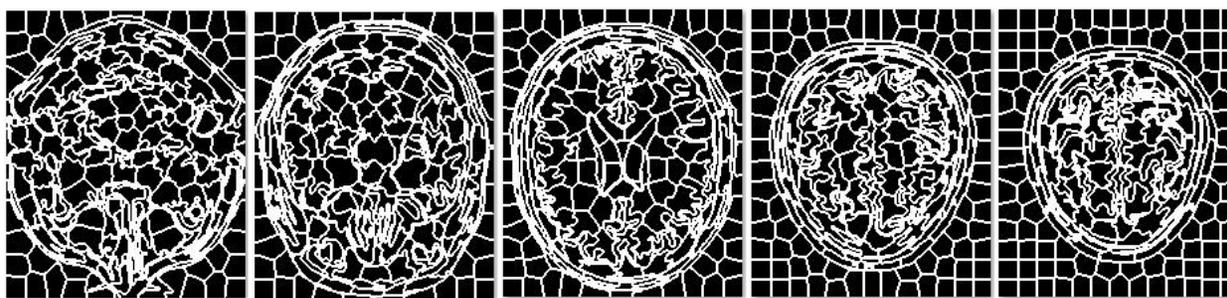


Figura 5.13. Algunas de las imágenes segmentadas mediante LSC de OpenCV

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y *Linear Spectral Clustering* (LSC), aplicando la métrica de Entropía Cruzada (CE), para selección de la mejor imagen segmentada, cuyos resultados (Figura 5.14), muestran un mejor desempeño de ICM respecto de LSC.

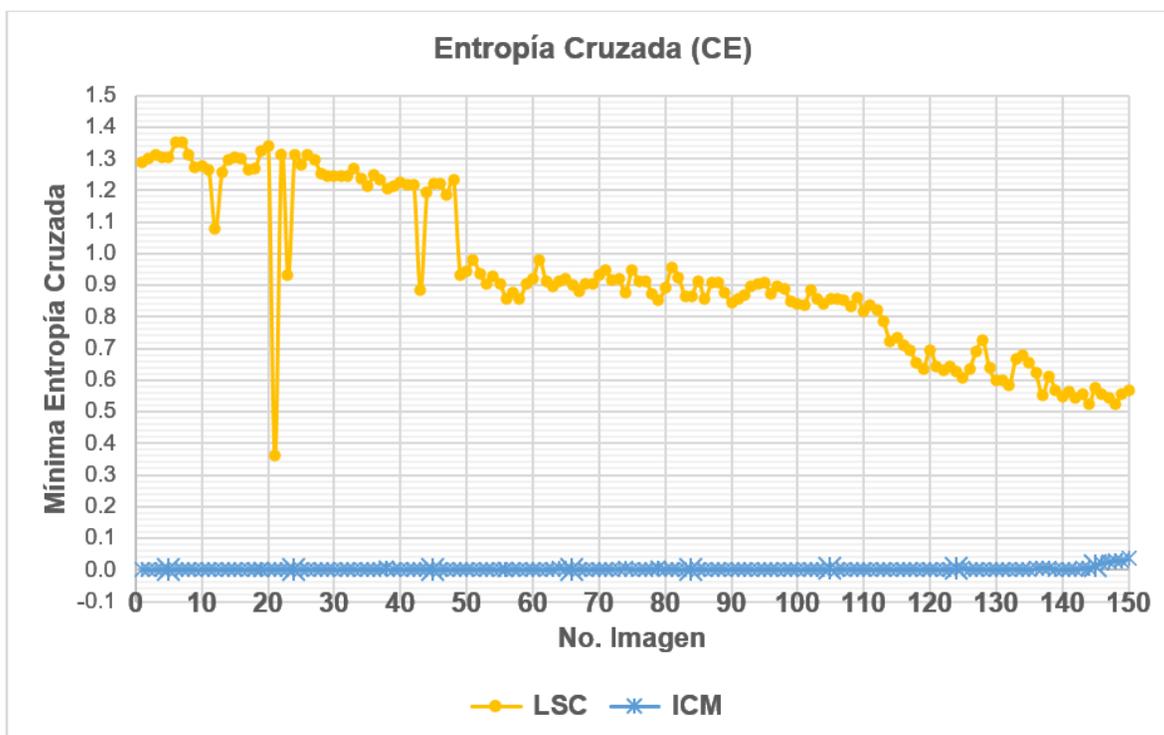


Figura 5.14. Comparación de la Entropía Cruzada para 150 imágenes aplicando segmentación ICM y LSC

5.3 Segmentación ICM bajo la Métrica Entropía (H)

Hasta este punto de este trabajo, se realizaron estudios de segmentación de tipo comparativo entre ICM y Canny bajo la métrica de máxima Entropía (H) y Contraste del Nivel de Gris (GC), y también entre ICM y los segmentadores Canny, Sobel, *Watershed* (W) y *Linear Spectral Clustering* (LSC), bajo la métrica de Entropía Cruzada, mostrando resultados favorables para ICM. Sin dejar esta línea de trabajo, se realiza el mismo estudio, pero ahora con la métrica (criterio) de Entropía (H), y los segmentadores Sobel, *Watershed* (W), y *Linear Spectral Clustering* (LSC).

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y Sobel aplicando la métrica de la Entropía (H),

para seleccionar la mejor imagen segmentada, cuyos resultados (Figura 5.15), muestran un mejor desempeño de ICM respecto de Sobel.

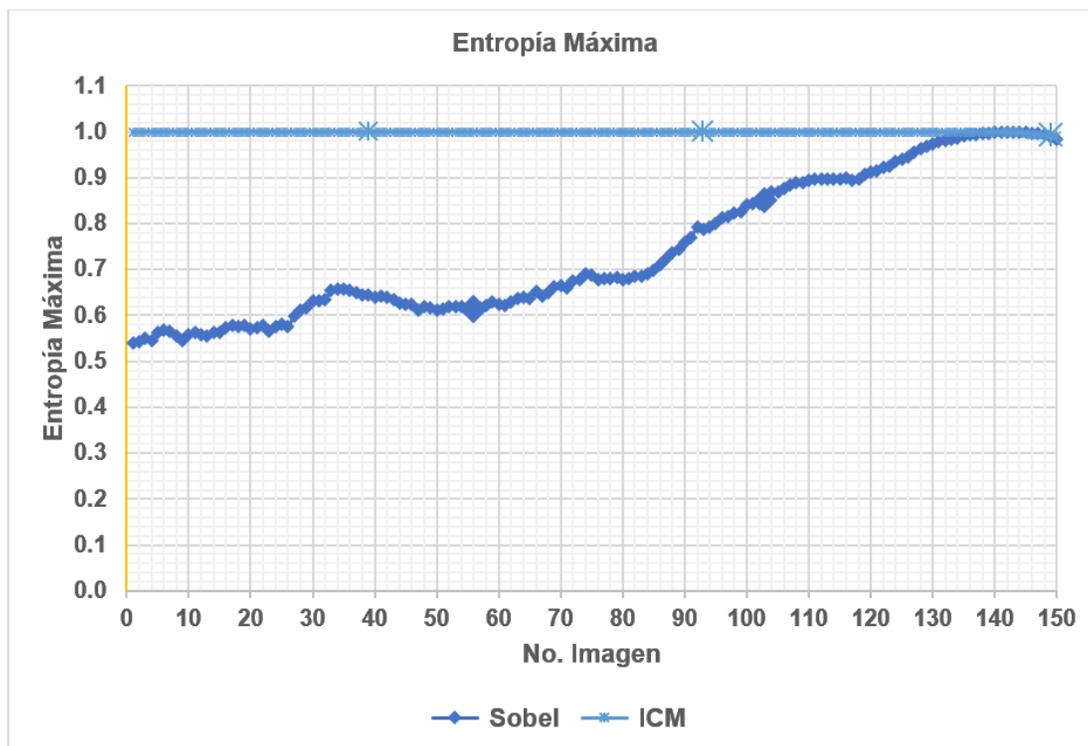


Figura 5.15. Comparación de la Entropía para 150 imágenes aplicando segmentación ICM y Sobel

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y *Watershed*, aplicando la métrica de la Entropía (H) para seleccionar la mejor imagen segmentada, cuyos resultados (Figura 5.16), muestran un mejor desempeño de ICM respecto de *Watershed*.

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y *Linear Spectral Clustering* (LSC), aplicando la métrica de la Entropía (H) para seleccionar la mejor imagen segmentada, cuyos resultados (Figura 5.17), muestran un mejor desempeño de ICM respecto de LSC.

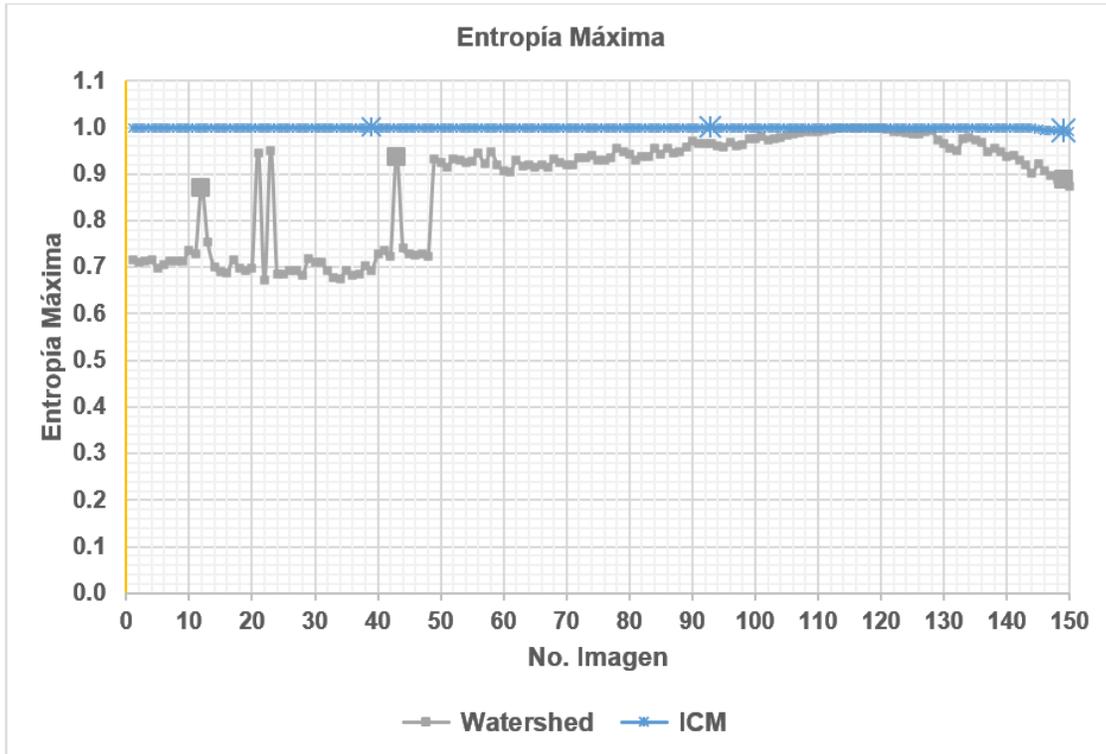


Figura 5.16. Comparación de la Entropía para 150 imágenes aplicando segmentación ICM y *Watershed*

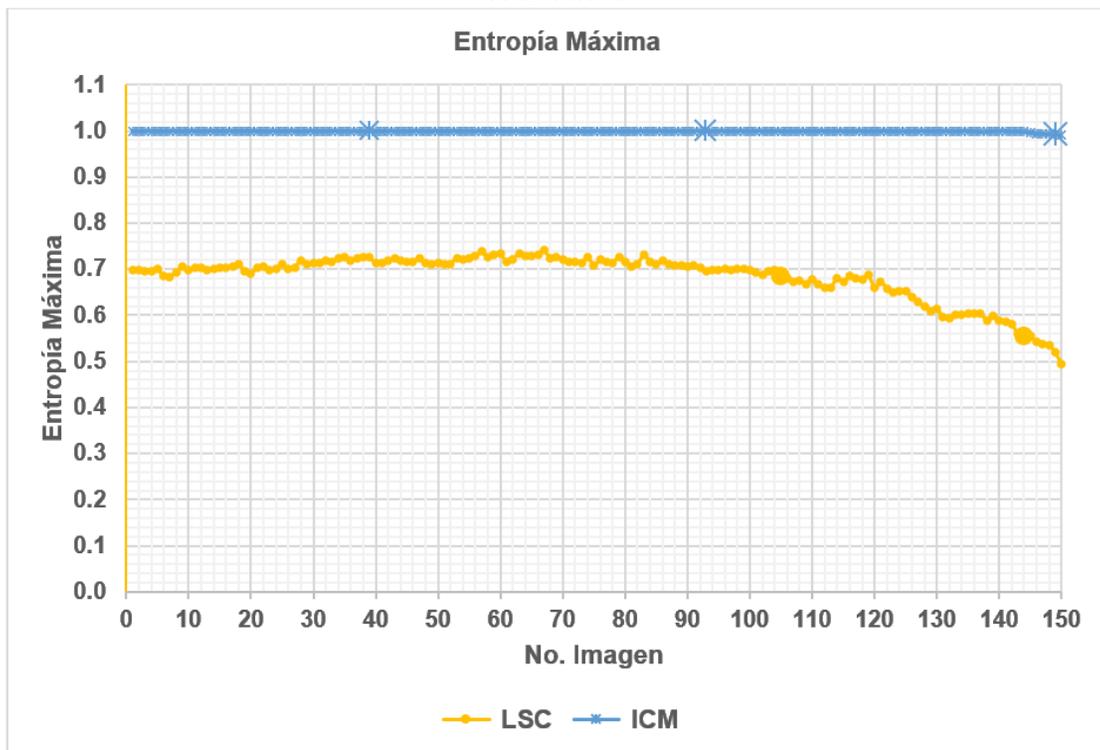


Figura 5.17. Comparación de la Entropía para 150 imágenes aplicando segmentación ICM y LSC

5.4 Segmentación ICM bajo la Métrica Contraste del Nivel de Gris (GC)

En este apartado se realiza estudio de segmentación entre ICM y los segmentadores Sobel, *Watershed* (W), y *Linear Spectral Clustering* (LSC), bajo la métrica (criterio) de Contraste del Nivel de Gris (GC).

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y Sobel aplicando la métrica del Contraste del Nivel de Gris (GC), para seleccionar la mejor imagen segmentada, cuyos resultados se muestran en la Figura 5.18.

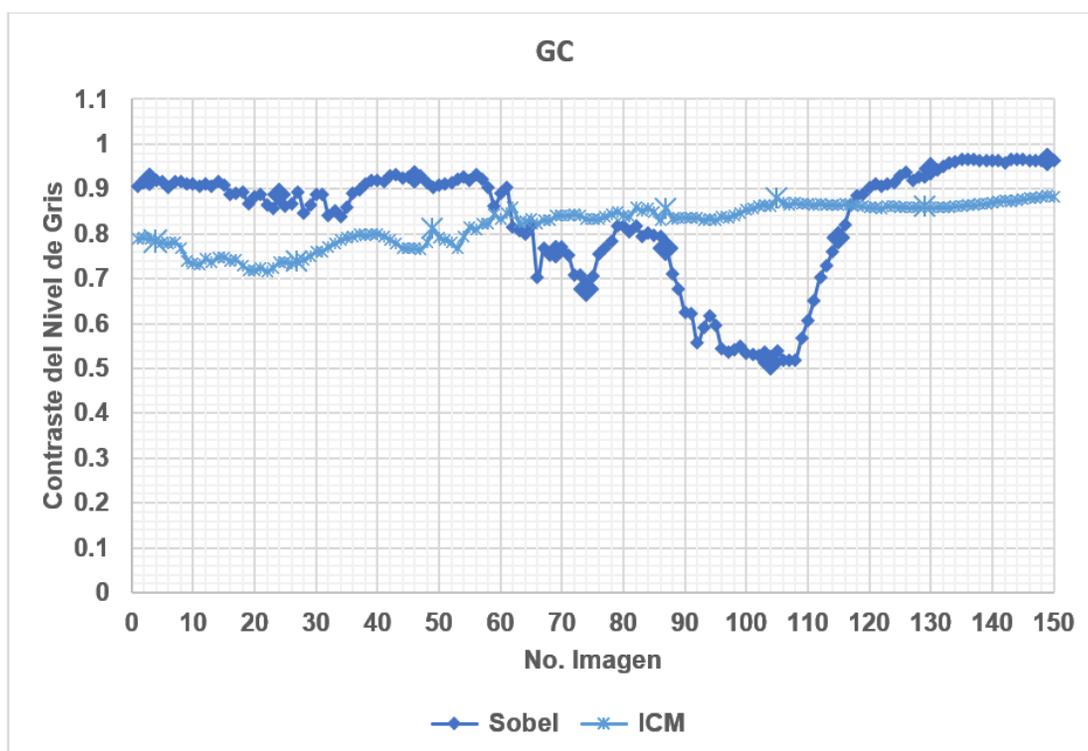


Figura 5.18. Comparación del Contraste del Nivel de Gris para 150 imágenes aplicando segmentación ICM y Sobel

Como se puede observar en las gráficas de Contraste del Nivel de Gris, para ICM y Sobel, de la Figura 5.18, existen dos rangos de imágenes para los cuales Sobel se desempeña mejor en segmentación que ICM, y un rango de imágenes en que ICM se desempeña mejor que Sobel.

Se procesaron 150 imágenes del cerebro humano por segmentador, y se hizo una comparativa de segmentación entre ICM y *Watershed* aplicando la métrica del Contraste

del Nivel de Gris (GC), para seleccionar la mejor imagen segmentada, cuyos resultados (Figura 5.19) muestran un mejor desempeño de ICM respecto *Watershed*.

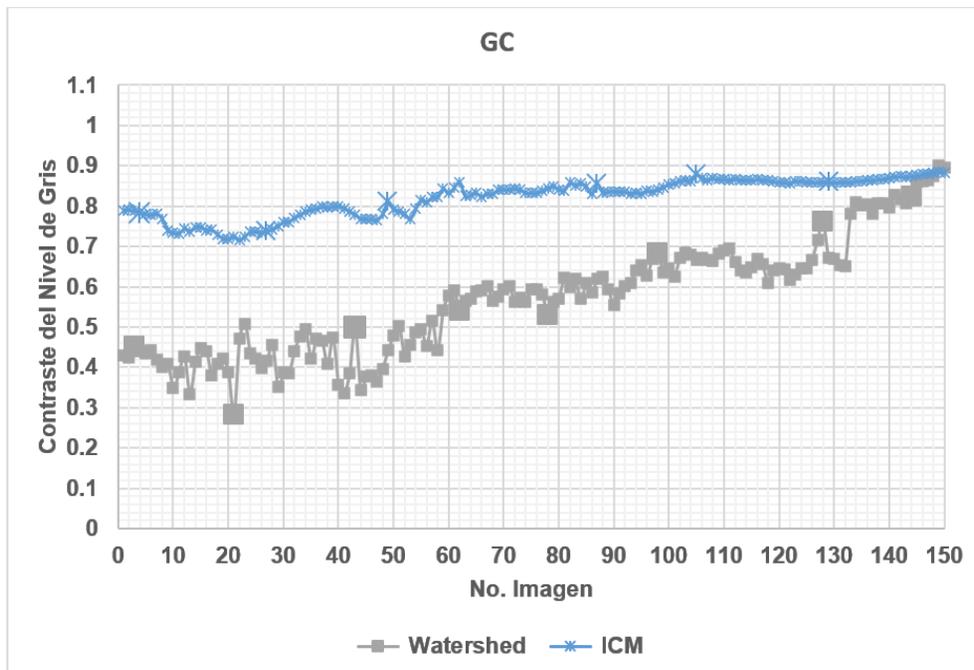


Figura 5.19. Comparación del Contraste del Nivel de Gris para 150 imágenes aplicando segmentación ICM y *Watershed*

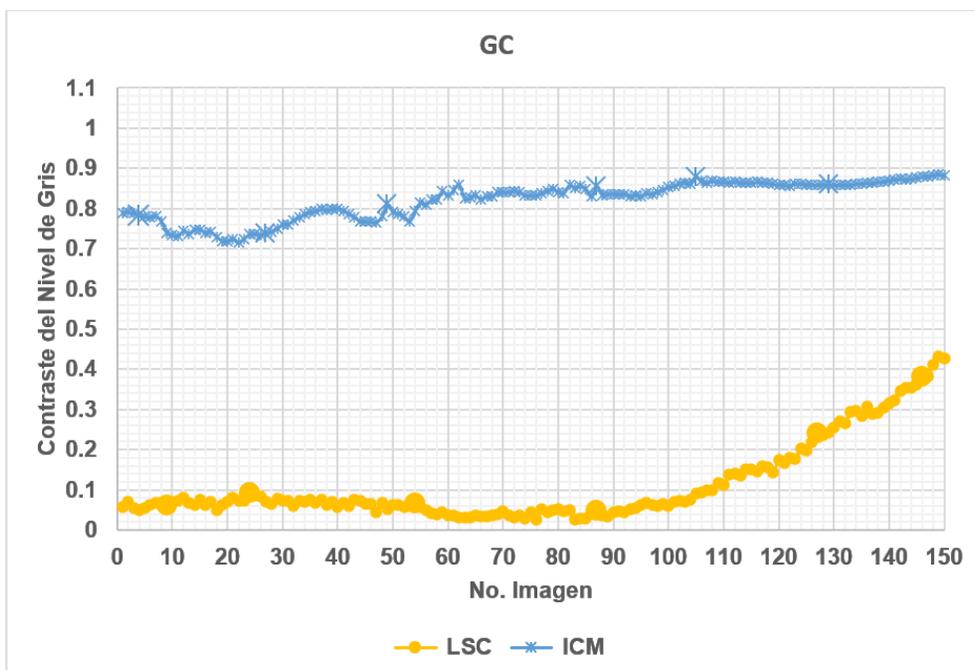


Figura 5.20. Comparación del Contraste del Nivel de Gris para 150 imágenes aplicando segmentación ICM y LSC

Se procesaron 150 imágenes del cerebro humano por cada segmentador, y se hizo una comparativa de segmentación entre ICM y *Linear Spectral Clustering* (LSC) aplicando la métrica del Contraste del Nivel de Gris (GC), para seleccionar la mejor imagen segmentada, cuyos resultados (Figura 5.20) muestran un mejor desempeño de ICM respecto LSC.

El estudio anterior se realizó paso a paso según la secuencia mostrada, experimentando con ICM y un segmentador y métrica diferente a la vez, para visualizar cualquier situación irregular que pudiera surgir y solventando esas diferentes dificultades encontradas en el proceso.

En el siguiente apartado se realiza un análisis de resultados de manera conjunta entre segmentadores, bajo una métrica en particular.

5.5 Análisis de Resultados por Métrica Aplicada

Una vez alcanzados los resultados anteriores, el siguiente paso es efectuar un análisis de resultados del estudio comparativo realizado, pero ahora llevado a cabo en forma conjunta con todos los segmentadores involucrados y por cada métrica aplicada.

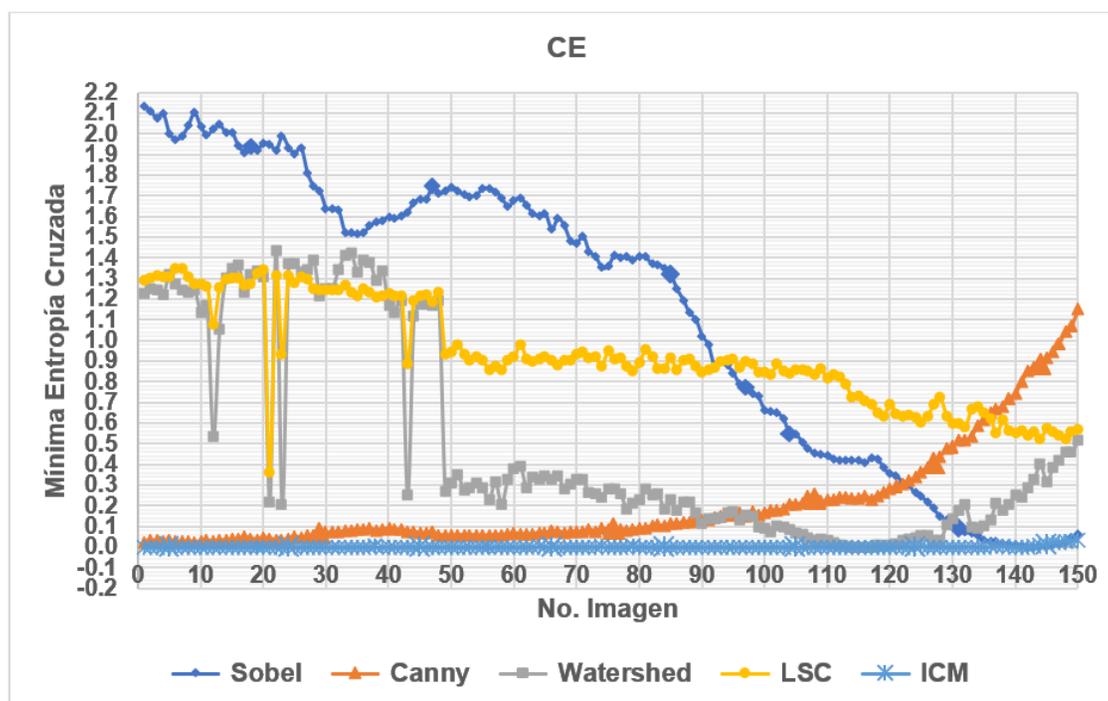


Figura 5.21. Comparativa de segmentación entre la Red Neuronal ICM, y los diferentes segmentadores aplicando la métrica de Entropía Cruzada (CE)

Se procesaron 150 imágenes del cerebro humano por cada segmentador, y se realizó una comparativa de segmentación entre ICM y los algoritmos de Canny, Sobel, *Watershed* y *Linear Spectral Clustering* (LSC), bajo la métrica Entropía Cruzada (CE).

En la Figura 5.21 se muestran los resultados obtenidos en la que podemos observar que, bajo la métrica de Entropía Cruzada (CE), ICM tiene un mejor desempeño que el resto de los segmentadores.

Se procesaron 150 imágenes del cerebro humano por cada segmentador, y se realizó una comparativa de segmentación entre la Red Neuronal ICM y los algoritmos de Canny, Sobel, *Watershed* y *Linear Spectral Clustering* (LSC), bajo la métrica Entropía (H).

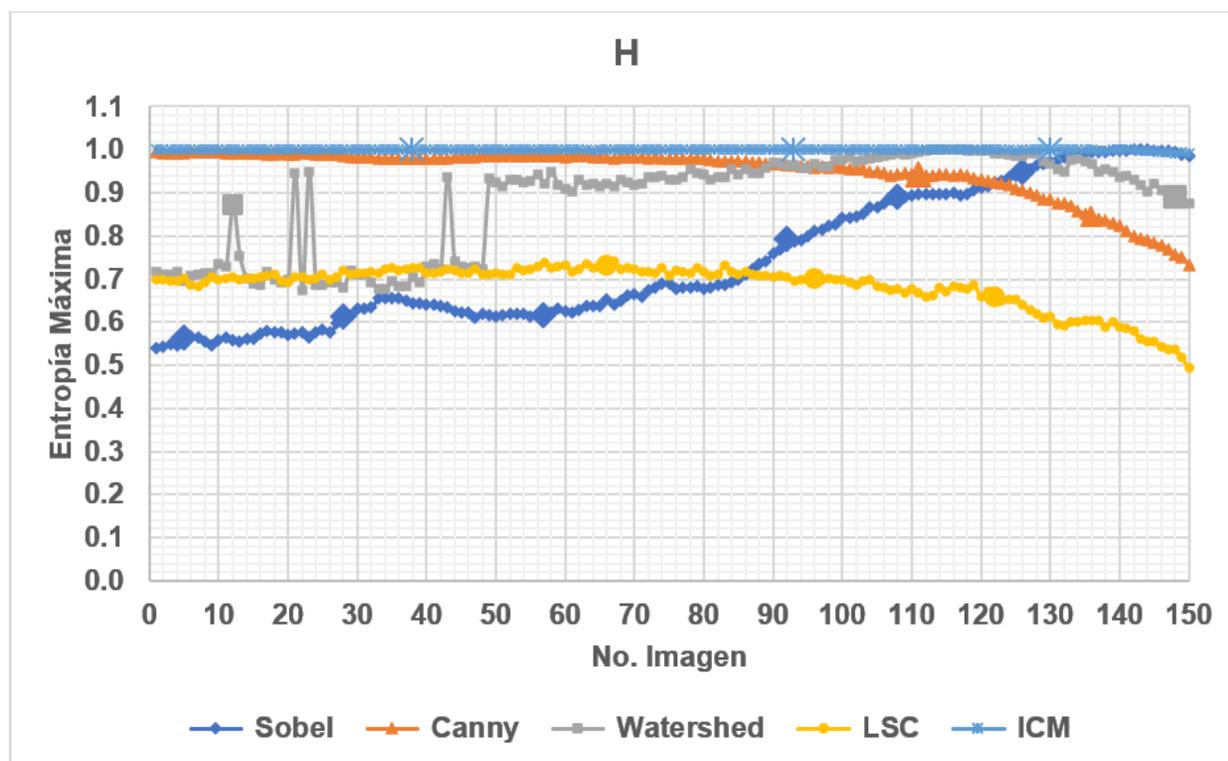


Figura 5.22. Comparativa de segmentación entre la Red Neuronal ICM, y los diferentes segmentadores aplicando la métrica de Entropía (H)

En las gráficas de la Figura 5.22 se muestran los resultados obtenidos, en la que podemos observar que, bajo la métrica de Entropía (H), ICM tiene un mejor desempeño que el resto de los segmentadores.

Se procesaron 150 imágenes del cerebro humano por cada segmentador, y se realizó una comparativa de segmentación entre ICM y los algoritmos de Canny, Sobel,

Watershed y *Linear Spectral Clustering* (LSC), bajo la métrica Contraste del Nivel de Gris (GC).

En las gráficas de la Figura 5.23 se muestran los resultados obtenidos al aplicar la métrica del Contraste del Nivel de Gris (GC). Se observan mejores resultados de ICM respecto al resto de segmentadores excepto para Sobel, con respecto del cual ICM sólo presenta mejores resultados para un rango de imágenes. En los otros dos intervalos de imágenes Sobel presenta un mejor desempeño.

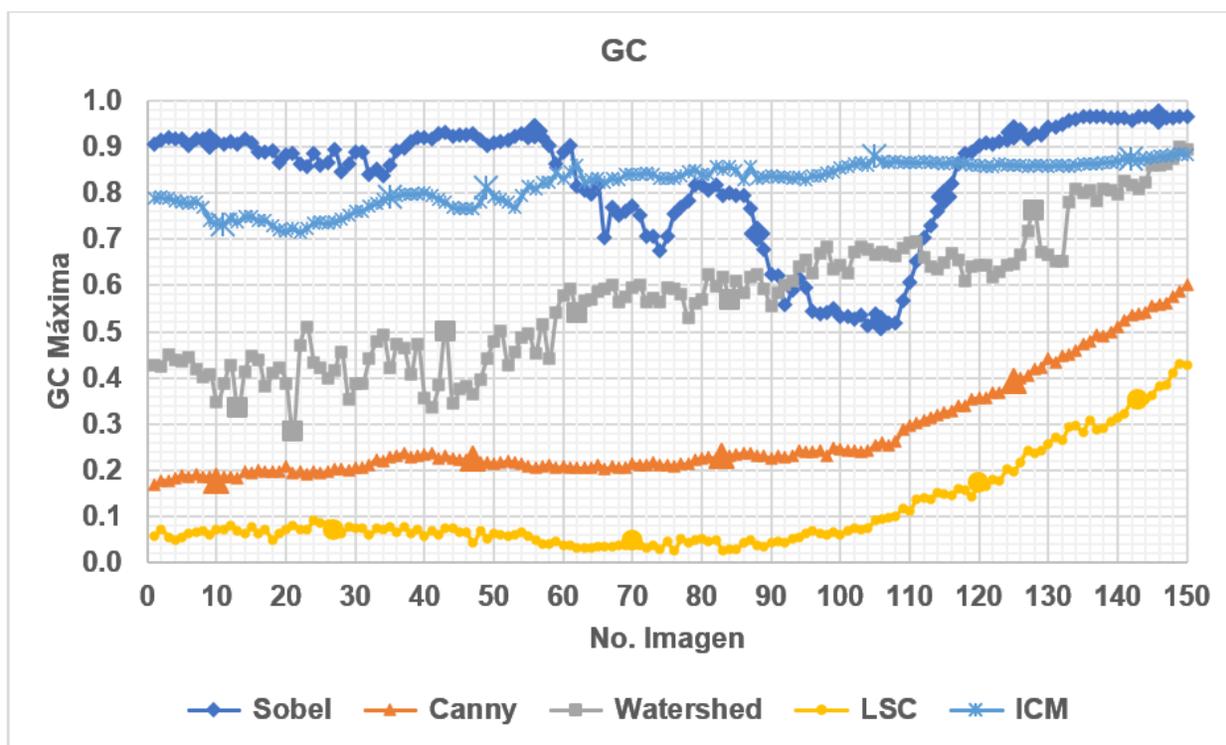


Figura 5.23. Comparativa de segmentación entre la Red Neuronal ICM, y los diferentes segmentadores aplicando la métrica de Contraste del Nivel de Gris (GC)

Se introduce una cuarta métrica (criterio) *Overall Merit* (OM), sugerido en [Ma, 2010]. La aplicación de esta métrica reafirma los resultados dados con anterioridad al aplicar las otras métricas.

Se procesaron 150 imágenes del cerebro humano por cada segmentador, y se realizó una comparativa de segmentación entre ICM y los algoritmos de Canny, Sobel, *Watershed* y *Linear Spectral Clustering* (LSC), bajo la métrica *Overall Merit* (OM).

En las gráficas de la Figura 5.24 se muestran los resultados obtenidos al aplicar la métrica *Overall Merit* (OM). Se observa que la curva de Sobel está por encima de la

curva de ICM en un pequeño rango de imágenes, reflejando el hecho de que, aunque ICM se comporta mejor que Sobel bajo la métrica GC para un cierto intervalo de imágenes, Sobel es mejor que ICM en dos rangos de imágenes. Respecto al resto de los segmentadores, como se esperaba, ICM tiene mejores resultados.

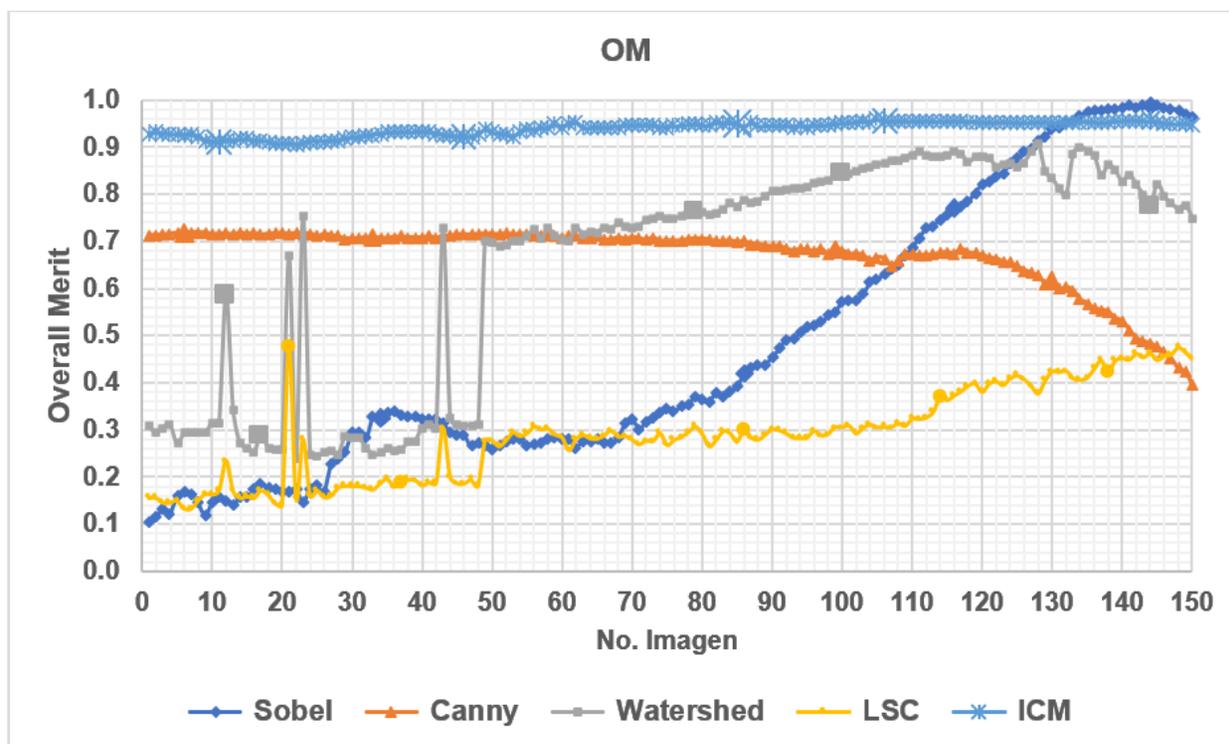


Figura 5.24. Comparativa de segmentación entre la Red Neuronal ICM, y los diferentes segmentadores aplicando la métrica de *Overall Merit* (OM)

5.6 Distancia promedio entre resultados de ICM y el resto de segmentadores

A continuación, se muestran las gráficas (Figuras 5.25 a 5.28) con las distancias promedio entre los resultados de segmentación de ICM y los diferentes resultados obtenidos por los segmentadores: Canny, Sobel, Watershed y LSC, bajo las métricas de la Entropía (H), Contraste del Nivel de Gris (GC), Entropía Cruzada (CE) y Overall Merit (OM).

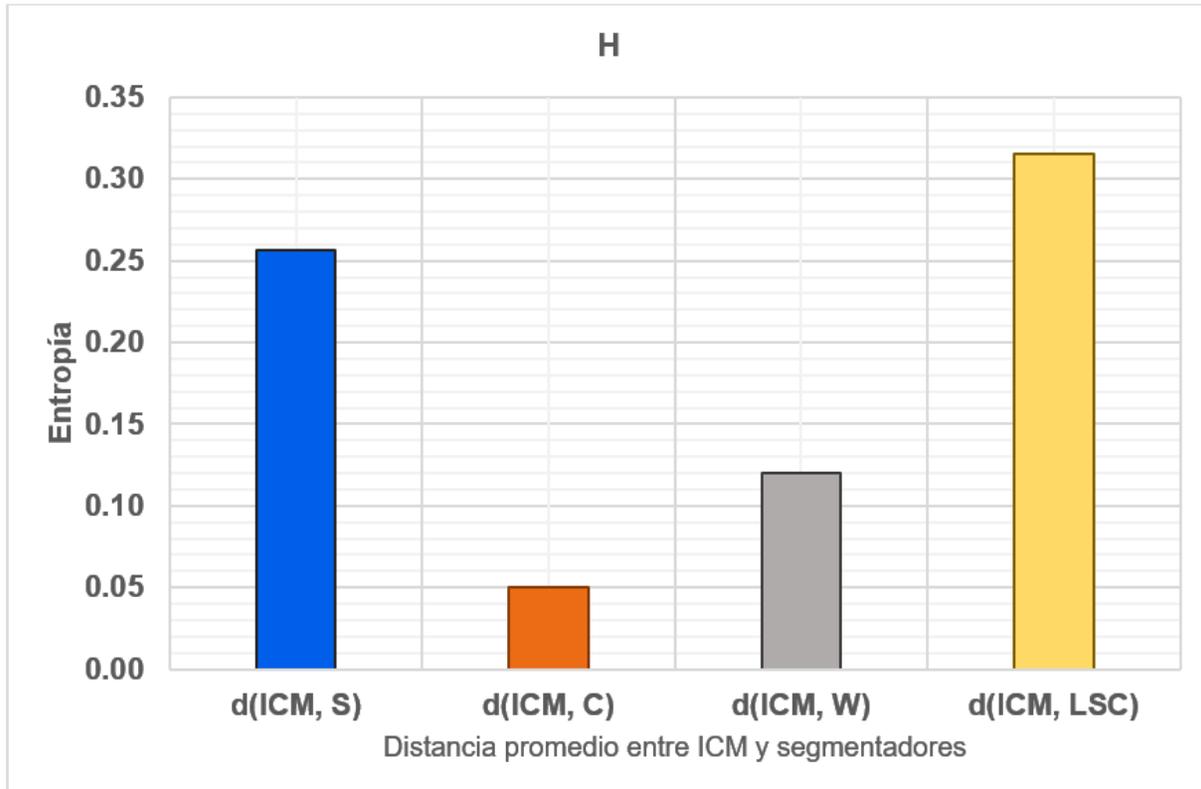


Figura 5.25. Distancia promedio entre los resultados de ICM y el resto de segmentadores bajo la métrica Entropía (H)

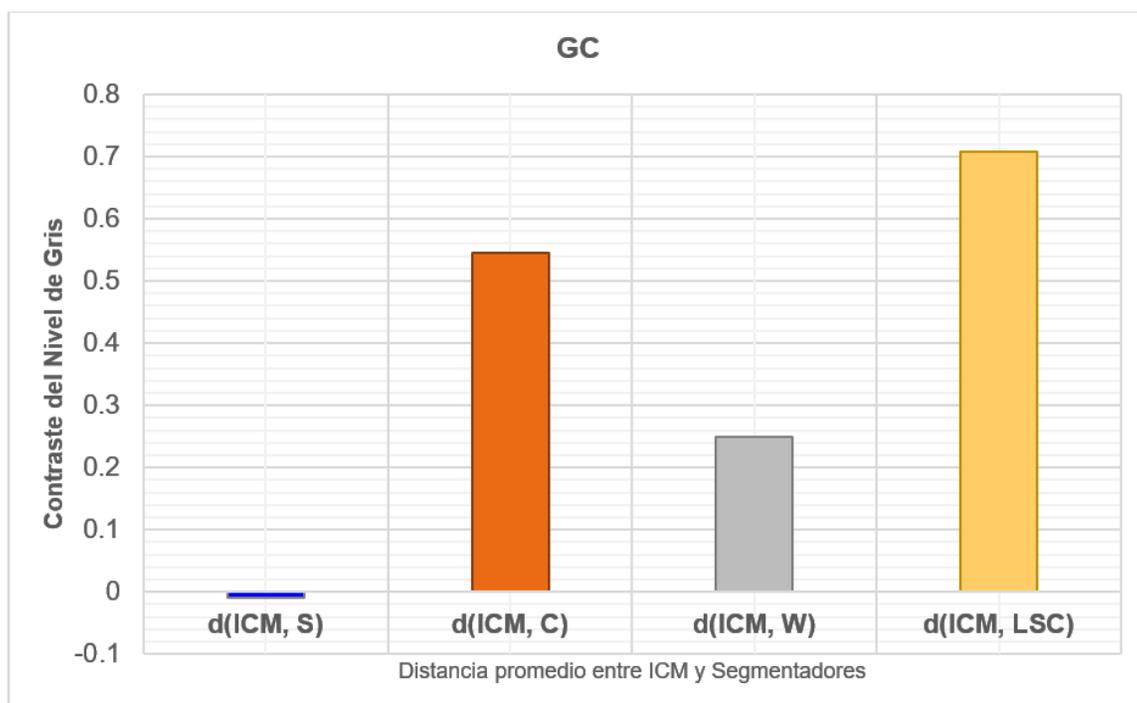


Figura 5.26. Distancia promedio entre los resultados de ICM y el resto de segmentadores bajo la métrica Nivel de Gris (GC)

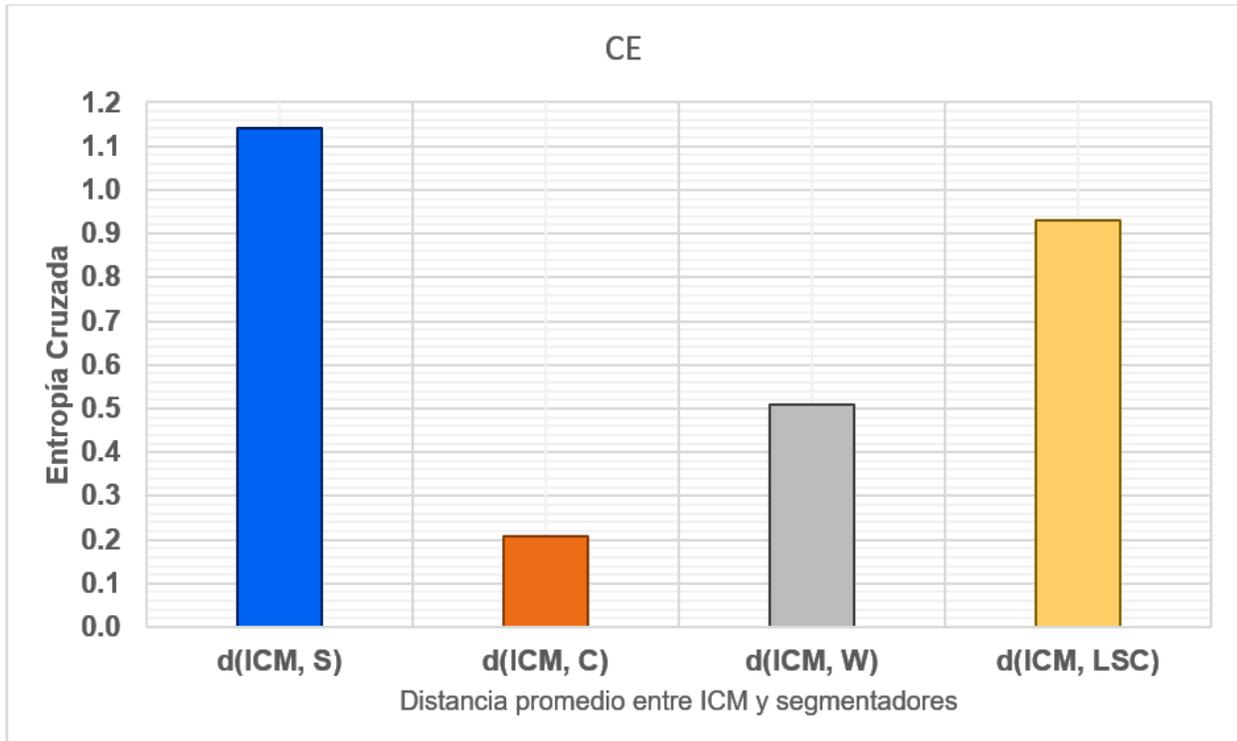


Figura 5.27. Distancia promedio entre los resultados de ICM y el resto de segmentadores bajo la métrica Entropía Cruzada (CE)

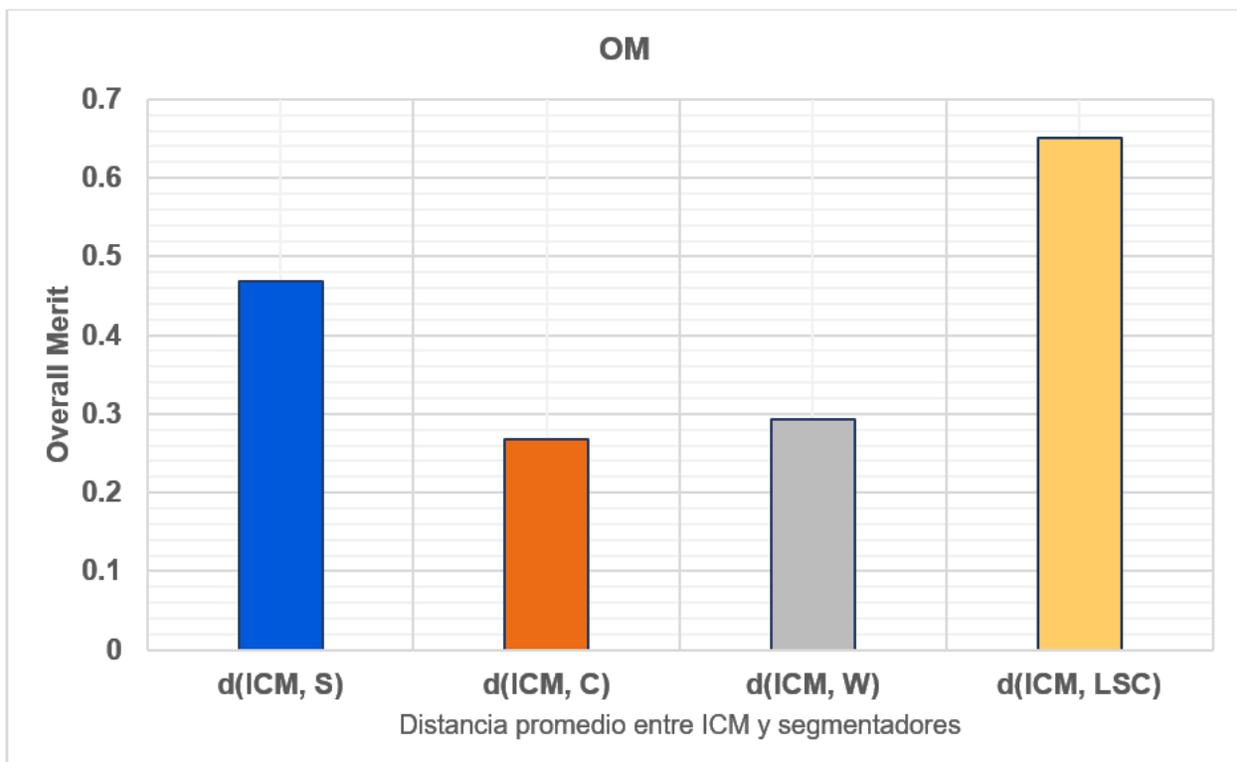


Figura 5.28. Distancia promedio entre los resultados de ICM y el resto de segmentadores bajo la métrica Overall Merit (OM)

En las gráficas anteriores $d(\text{ICM} - \text{S})$, $d(\text{ICM} - \text{C})$, $d(\text{ICM} - \text{W})$, $d(\text{ICM} - \text{LSC})$ representan las **distancias promedio** entre ICM y los segmentadores: Sobel, Canny, *Watershed*, y LSC, respectivamente, que resultan de restar los valores obtenidos de las imágenes segmentadas de ICM y los valores obtenidos de las imágenes segmentadas correspondientes de los segmentadores: Sobel, Canny, *Watershed* y LSC respectivamente, bajo las métricas de la Entropía (**H**), Contraste del Nivel de Gris (**GC**), Entropía Cruzada (**CE**) y Overall Merit (**OM**) respectivamente en cada grafica.

En el caso de la distancia promedio entre ICM y Sobel, bajo la métrica Contraste del Nivel de Gris (GC), Figura 5.25, se observa que, en promedio, Sobel e ICM muestran un empate en desempeño respecto al resto de los segmentadores, destacando ligeramente Sobel.

5.7. Muestras de Segmentaciones Realizadas

En las Figuras 5.29 a 5.48, se muestran ejemplos de las imágenes segmentadas. De izquierda a derecha: Imagen original, imágenes segmentadas mediante Canny, ICM, LSC, Sobel y *Watershed*, respectivamente. Se muestran también los valores obtenidos de la métrica aplicada indicada.

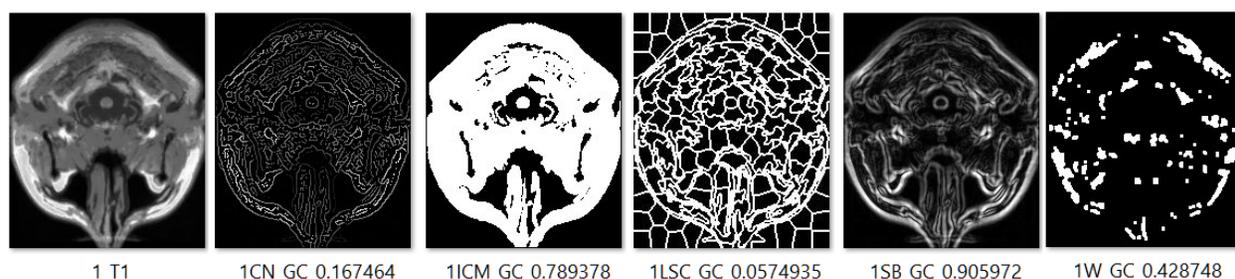


Figura 5.29. Ejemplos de segmentación. Métrica aplicada: **Contraste del Nivel de Gris (GC)**

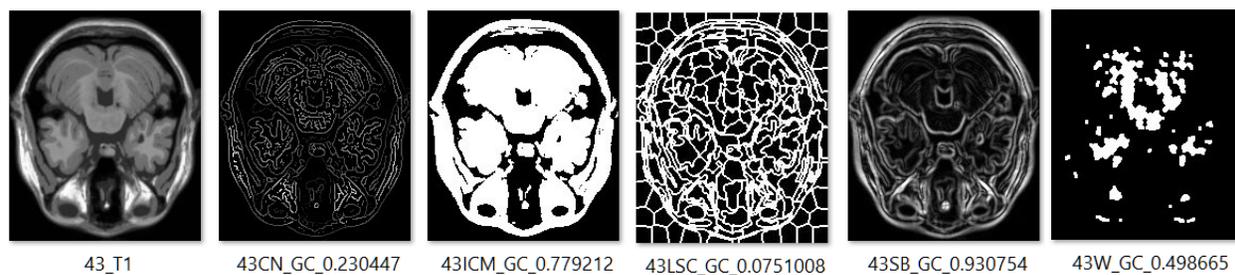


Figura 5.30. Ejemplos de segmentación. Métrica aplicada: **Contraste del Nivel de Gris (GC)**

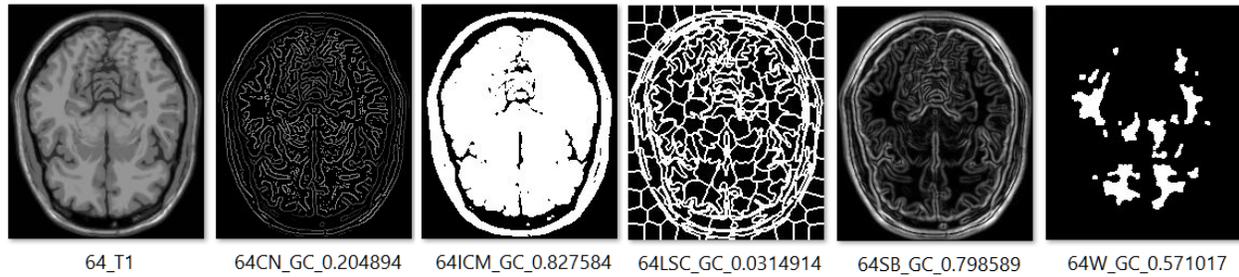


Figura 5.31. Ejemplos de segmentación. Métrica aplicada: **Contraste del Nivel de Gris (GC)**

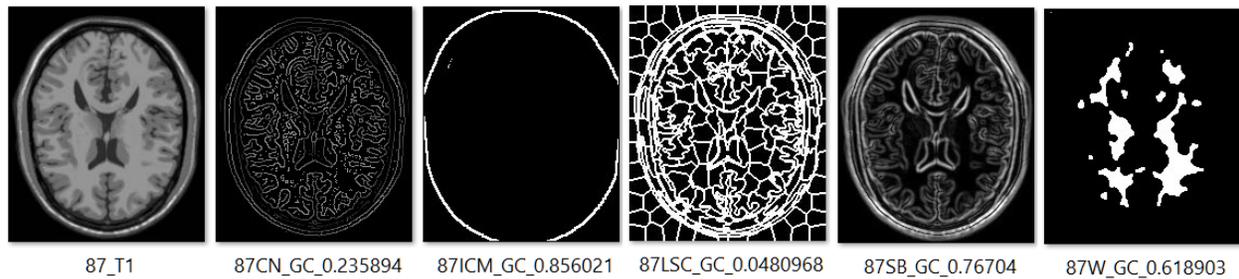


Figura 5.32. Ejemplos de segmentación. Métrica aplicada: **Contraste del Nivel de Gris (GC)**



Figura 5.33. Ejemplos de segmentación. Métrica aplicada: **Contraste del Nivel de Gris (GC)**

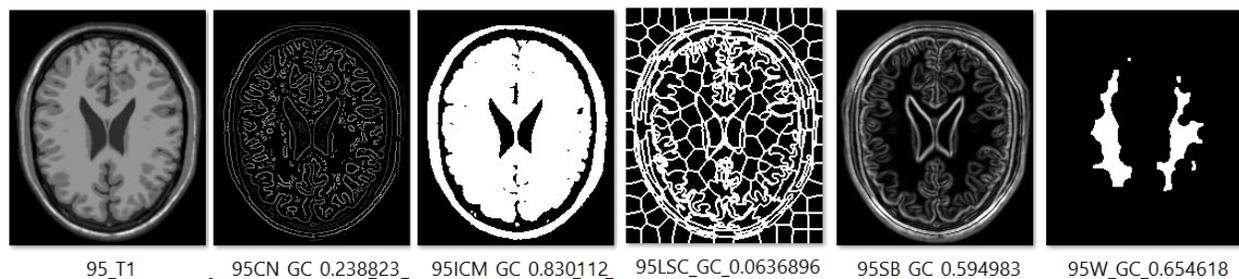


Figura 5.34. Ejemplos de segmentación. Métrica aplicada: **Contraste del Nivel de Gris (GC)**

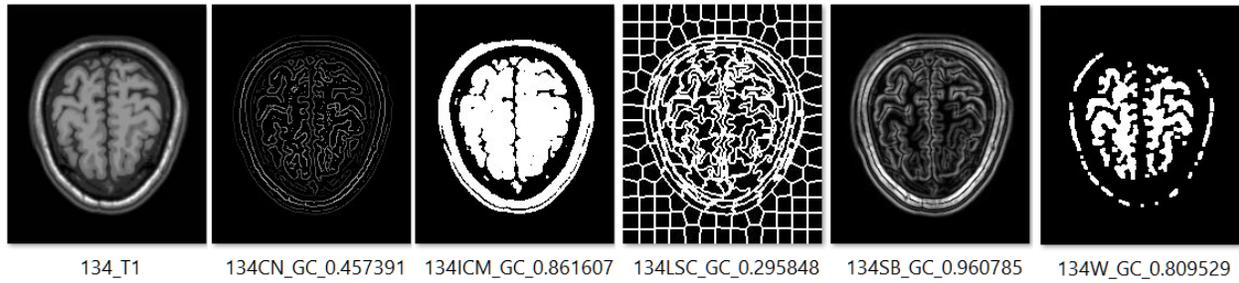


Figura 5.35. Ejemplos de segmentación. Métrica aplicada: **Contraste del Nivel de Gris (GC)**

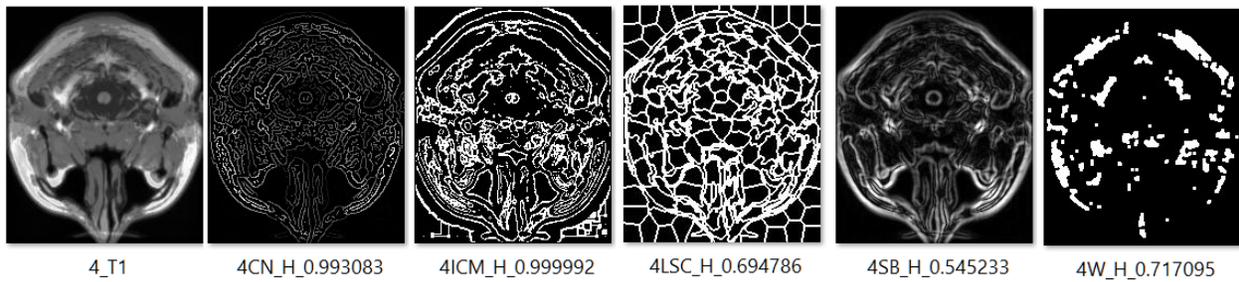


Figura 5.36. Ejemplos de segmentación. Métrica aplicada: **Entropía (H)**

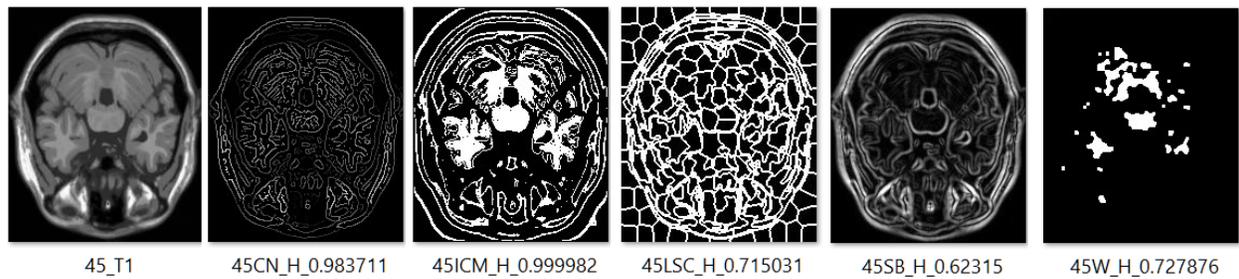


Figura 5.37. Ejemplos de segmentación. Métrica aplicada: **Entropía (H)**

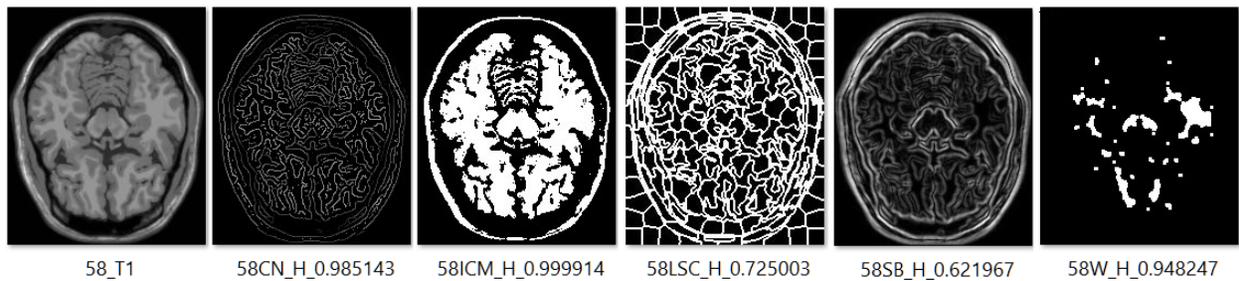


Figura 5.38. Ejemplos de segmentación. Métrica aplicada: **Entropía (H)**



Figura 5.39. Ejemplos de segmentación. Métrica aplicada: **Entropía (H)**

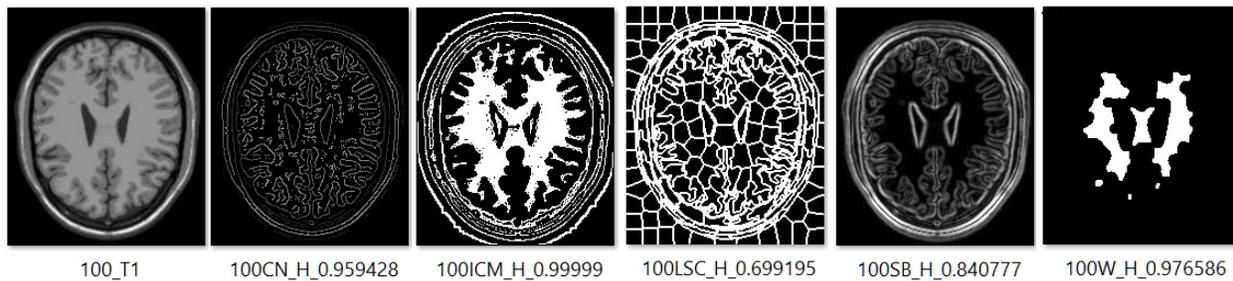


Figura 5.40. Ejemplos de segmentación. Métrica aplicada: **Entropía (H)**

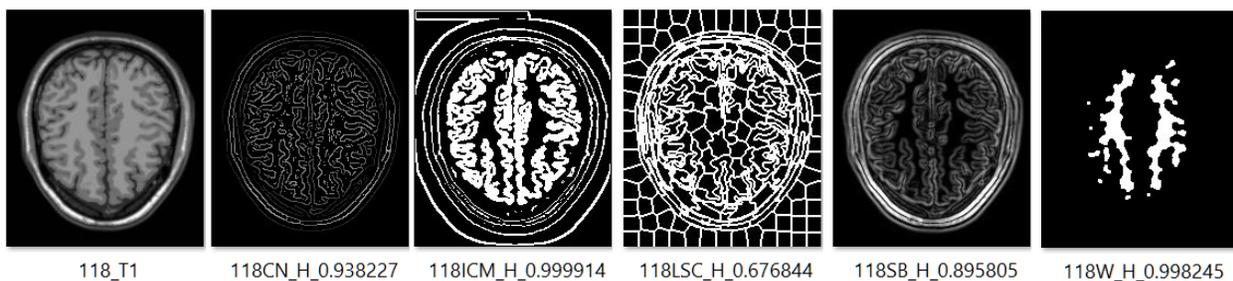


Figura 5.41. Ejemplos de segmentación. Métrica aplicada: **Entropía (H)**

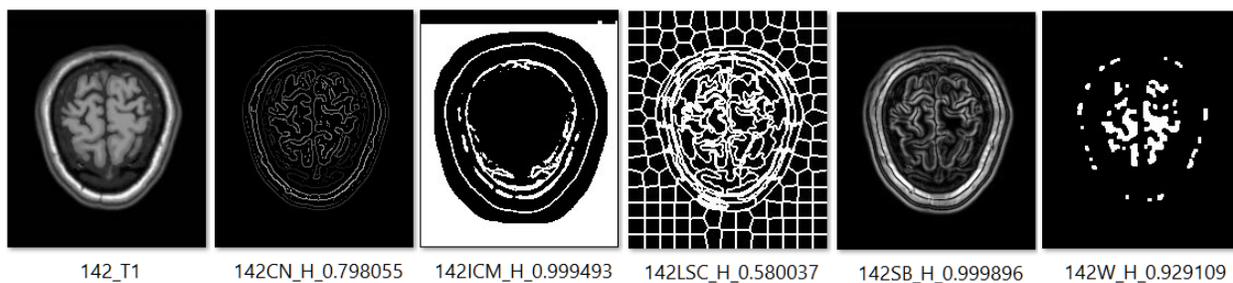


Figura 5.42. Ejemplos de segmentación. Métrica aplicada: **Entropía (H)**

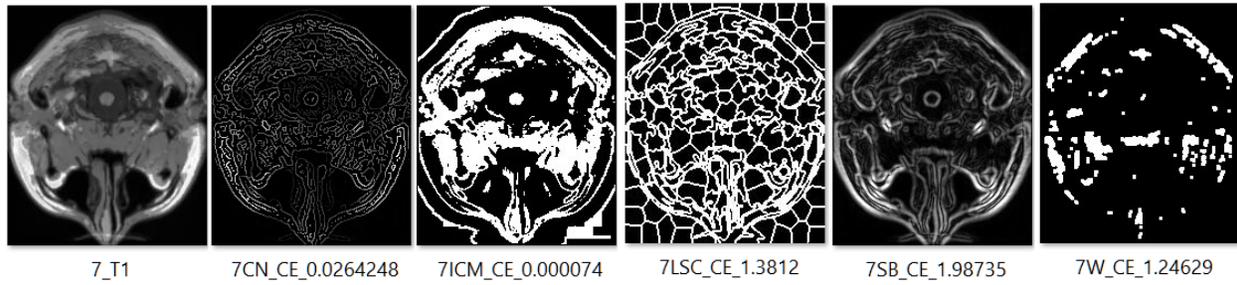


Figura 5.43. Ejemplos de segmentación. Métrica aplicada: **Entropía Cruzada (CE)**

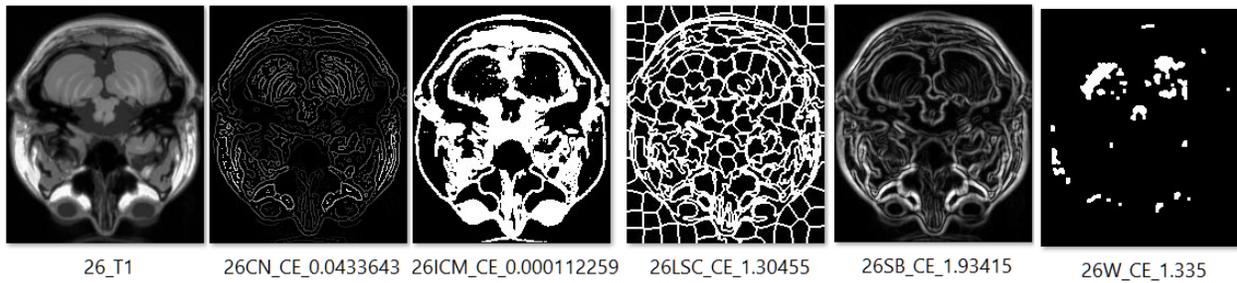


Figura 5.44. Ejemplos de segmentación. Métrica aplicada: **Entropía Cruzada (CE)**

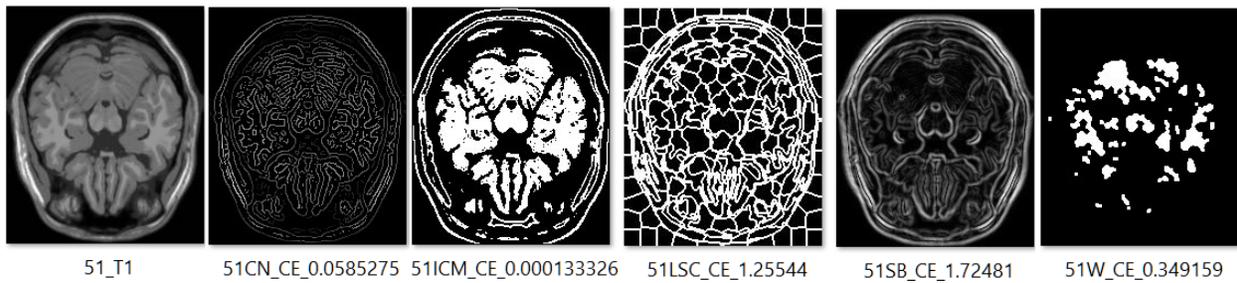


Figura 5.45. Ejemplos de segmentación. Métrica aplicada: **Entropía Cruzada (CE)**

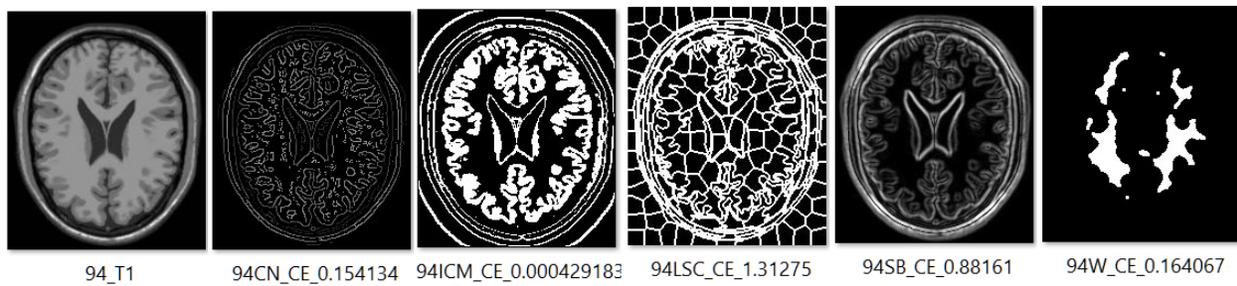


Figura 5.46. Ejemplos de segmentación. Métrica aplicada: **Entropía Cruzada (CE)**

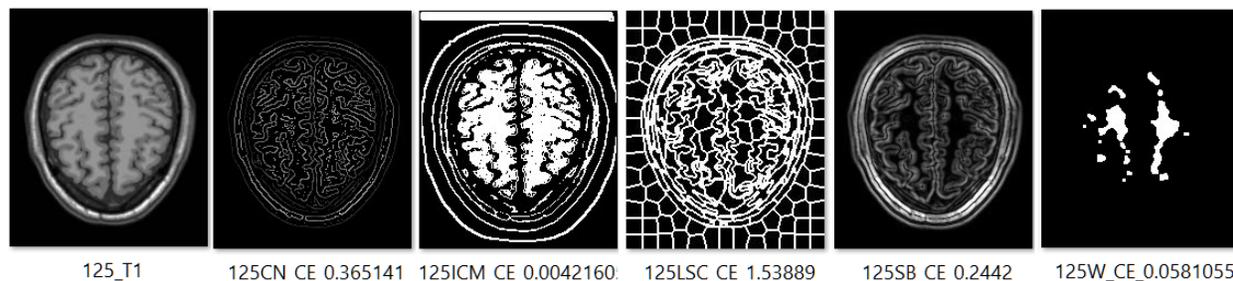


Figura 5.47. Ejemplos de segmentación. Métrica aplicada: **Entropía Cruzada (CE)**

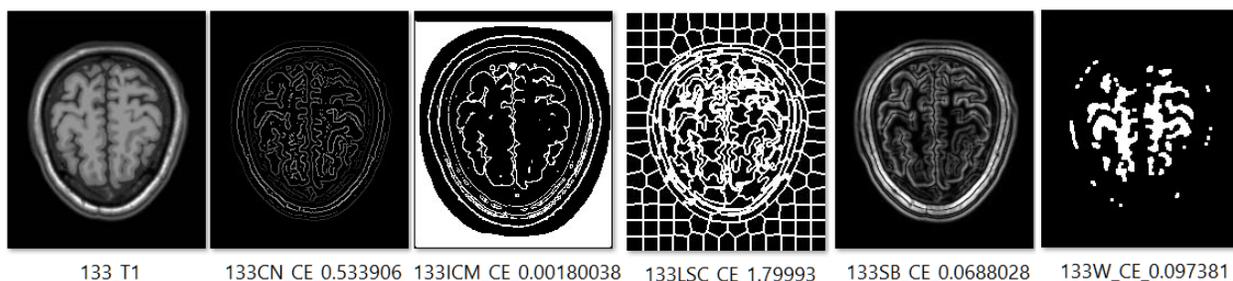


Figura 5.48. Ejemplos de segmentación. Métrica aplicada: **Entropía Cruzada (CE)**

5.8. Discusión

Un análisis de resultados del trabajo realizado, a la luz de los resultados obtenidos, y desde una perspectiva cuantitativa, el estudio comparativo anterior muestra que, en cuanto a segmentación de imágenes digitales del cerebro humano, utilizando imágenes de la base de datos *BrainWeb* [*BrainWeb* SDB], la Red Neuronal de Intersección Cortical (ICM), como procesador de imágenes digitales, tiene mejor desempeño que los segmentadores seleccionados: Canny, Sobel, *Watershed* (W) y *Linear Spectral Clustering* (LSC), bajo las métricas aplicadas: Entropía (H), Contraste del Nivel de Gris (GC), Entropía Cruzada (CE) y *Overall Merit* (OM), que evalúan la mejor imagen segmentada. Lo anterior, exceptuando el caso de la aplicación de la métrica Contraste del Nivel de Gris (GC), en el que ICM obtiene un empate con el segmentador Sobel, desempeñándose ligeramente mejor éste último.

Como se mencionó anteriormente, este estudio se basa sólo en números fríos, dejando de lado el aspecto cualitativo visual subjetivo, dado que según la Sección 1.7, este estudio no busca mejorar resultados, sino investigar el desempeño de la ICM en el campo de la segmentación de imágenes, bajo la aplicación de las diferentes métricas a los algoritmos segmentadores seleccionados.

Capítulo 6 Conclusiones

El presente trabajo de tesis inicia con una revisión de las aplicaciones de la Inteligencia Artificial (IA) en el área médica, la cual tiene como finalidad mejorar el diagnóstico médico, y en donde la imagen cerebral es un factor clave en la toma de decisiones clínicas. Es por esta razón que en el ámbito mencionado, cobra relevancia el procesamiento, segmentación y clasificación de imágenes del cerebro humano con diferentes propósitos de estudio, y donde se han aplicado diversas técnicas de IA, lo que sirvió como motivación para realizar un estudio de las Redes Neuronales Pulso Acopladas (PCNN), dado que presentan una interesante perspectiva alterna de aplicación en procesamiento, segmentación y clasificación de imágenes dentro del dominio de la Visión Artificial, gracias a su adaptación natural al procesamiento de imágenes, por ser un Modelo de Red Neuronal cercano al Modelo Neuronal Biológico.

Ahondar un poco más en el estudio de la PCNN, específicamente, en el Modelo Neuronal de Intersección Cortical (ICM), en el campo de la segmentación de imágenes, justifica el presente trabajo, centrado en un estudio comparativo entre el segmentador ICM, y los segmentadores: Canny, Sobel, *Watershed* y LSC, bajo las métricas (criterios), de la Entropía, Contraste del Nivel de Gris, Entropía Cruzada y *Overall Merit*, que seleccionan la mejor imagen segmentada.

En este capítulo se hace una revisión del aparato que sustenta este documento de tesis, personificado en los objetivos, alcances, tal vez las limitaciones, así como la metodología para su realización, y se dan las conclusiones alusivas a los logros alcanzados por cada uno de ellos, los productos y participaciones realizadas, así como las conclusiones y trabajo futuro, como sigue:

6.1. Logros alcanzados

Se realiza análisis del logro de objetivos, alcances, limitaciones y metodología de solución del proyecto de tesis.

6.1.1 Objetivo general “Analizar, experimentar y evaluar la RNA tipo Pulse-Coupled Neural Network (PCNN) en el dominio de la Visión Artificial para la segmentación de imágenes digitales del cerebro humano cuyos resultados pudieran ser la entrada a una herramienta auxiliar en el área médica”.

Según el Capítulo 5: Experimentación y Resultados, Sección 5.8, se realizó con éxito el Estudio Comparativo de segmentación de imágenes digitales del cerebro humano, y eje central de este proyecto, utilizando imágenes de la base de datos *BrainWeb* [*BrainWeb* SDB], entre la Red Neuronal de Intersección Cortical (ICM), y el resto de segmentadores seleccionados, bajo las métricas aplicadas, en el que ICM, de manera general, muestra mejor desempeño en segmentación de imágenes que el resto de segmentadores, hecho que a la vez muestra que se cumplió el objetivo general propuesto.

6.1.2. Objetivos específicos

Objetivo específico 1. “Analizar y desarrollar el paradigma de Red Neuronal Pulso-Acoplada en forma computacional para el proceso de segmentación de imágenes digitales del cerebro humano”.

Se realizó todo un estudio y análisis del funcionamiento de la PCNN seleccionada, y desarrollada en C++, con lo cual, se cumple el presente objetivo.

Objetivo específico 2. “Definir casos de prueba y validación en el dominio de Visión Artificial, que sean indicadores del proceso adecuado de segmentación de la Red”.

Según se menciona en la Sección 4.3, con la experimentación preliminar se cumple el presente objetivo.

Objetivo específico 3. “Seleccionar por lo menos una base de datos de imágenes digitales del cerebro humano, para el proceso de segmentación de imágenes para utilizarse en estudio comparativo”.

Como se detalla en la Sección 4.5, la base de datos de imágenes utilizado en este trabajo es un banco de Imágenes de Resonancia Magnética (MRI) del cerebro humano encontrado en la Web, llamado *BrainWeb: Simulated Brain Database* [*BrainWeb* SDB], con lo cual se cumple el presente objetivo.

Objetivo específico 4. “Realizar un estudio comparativo para determinar el desempeño del paradigma de Red Neuronal Pulso-Acoplada como segmentador de imágenes digitales del cerebro humano, con algoritmos tradicionales de segmentación de imágenes sugeridos o reportados en la literatura”.

Como lo muestra la explicación dada en la Sección 6.1 de este capítulo, y la Sección 5.8 del Capítulo 5, “Experimentación y Resultados”, se realizó con éxito el Estudio Comparativo entre ICM y diferentes algoritmos segmentadores y métricas de evaluación, con lo cual se cumple el presente objetivo.

Objetivo específico 5. “Aplicar métricas de evaluación de desempeño de los diferentes algoritmos segmentadores involucrados en el estudio comparativo”.

Se seleccionaron las métricas para este propósito: Entropía (H), Contraste del Nivel de Gris (GC), Entropía Cruzada (CE) y *Overall Merit* (OM), que contribuyeron al logro del objetivo general, como lo muestran los resultados del capítulo 5, con lo cual se cumple el presente objetivo.

Objetivo específico 6. “Realizar un análisis de resultados”.

Como parte de la conclusión del Capítulo 5: Experimentación y Resultados, Sección 5.8, se realiza un análisis de resultados (más lo expuesto en este capítulo), con lo cual se cumple el presente objetivo.

6.1.3. Alcances del proyecto

Alcance 1. “Experimentar con bases de datos de Imágenes Resonancia Magnética (MRI) del cerebro humano encontradas en la comunidad de Visión Artificial (al menos una)”.

Se experimento con la base de datos de Imágenes de Resonancia Magnética (MRI) del cerebro humano *BrainWeb: Simulated Brain Database [BrainWeb SBD]*, con lo cual se cumple el presente alcance.

Alcance 2. “Realizar el estudio comparativo por lo menos con tres algoritmos tradicionales para la segmentación de imágenes sugeridos o encontrados en la comunidad de Visión Artificial”.

Para la realización del estudio comparativo con ICM, se seleccionaron y utilizaron cuatro algoritmos segmentadores Canny, Sobel, *Watershed* (W) y *Linear Spectral Clustering* (LSC), con lo cual se cumple el presente alcance.

Alcance 3. “Realizar el estudio comparativo aplicando por lo menos tres métricas sugeridas o encontrados en la comunidad de Visión Artificial, para evaluar el proceso de segmentación de imágenes”.

Se seleccionaron tres métricas para este propósito: Entropía (H), Contraste del Nivel de Gris (GC), Entropía Cruzada (CE), más una cuarta métrica (criterio) *Overall Merit* (OM), para evaluar el rendimiento de las métricas anteriores de manera exhaustiva, y que en conjunto contribuyeron al logro del objetivo general, como lo muestran los resultados del capítulo 5, con lo cual se cumple el presente alcance.

Alcance 4. “El estudio comparativo no busca mejorar resultados, sino investigar el desempeño de la PCNN en el campo de la segmentación de imágenes, a la luz de las diferentes métricas aplicadas a los algoritmos segmentadores seleccionados, independientemente del tipo y función del algoritmo segmentador”.

Los resultados del estudio comparativo dados a lo largo del capítulo 5, y en particular la Sección 5.8, ponen de manifiesto que, bajo el aparato de objetivos, alcances, limitaciones y metodología de este trabajo, la ICM mostró un buen desempeño como segmentador de imágenes digitales del cerebro humano, con lo cual se cumple el presente alcance.

Alcance 5. “El paradigma de Red Neuronal Pulso-Acoplada en estudio es el Modelo de Intersección Cortical (ICM)”.

Como se asienta al inicio del capítulo 4, y como se muestra a lo largo del capítulo 5, “Experimentación y resultados”, el estudio realizado en este trabajo se centra en el Modelo Neuronal de Interacción Cortical (ICM), con lo cual se cumple el presente alcance.

6.1.4. Limitaciones del proyecto

Limitante 1. “Las métricas y algoritmos utilizados en el estudio comparativo de segmentación de imágenes del cerebro humano se realizarán utilizando software de código libre y/o herramienta OpenCV”.

Se utilizaron algoritmos segmentadores de código abierto y/o OpenCV: Canny, Sobel, *Watershed* (H) y *Linear Spectral Clustering* (LSC), según lo especifica la Sección 4.7. En el caso de las métricas utilizadas no aplica, según se especifica en la Sección 4.6, con lo cual se justifica la presente limitante.

Limitante 2. “Realizar el estudio comparativo utilizando imágenes digitales del cerebro humano tal como se encuentran en la literatura, sin realizar modificaciones sustanciales como remoción de cráneo o uso de *ground truth*”.

En este trabajo se utiliza la modalidad T1 normal sin ruido, ni anomalías y el espesor por defecto, de la base de datos *BrainWeb: Simulated Brain Database* [*BrainWeb SBD*], como lo especifica la Sección 4.5, lo que justifica esta limitante.

Limitante 3. “Realizar el estudio comparativo utilizando imágenes digitales del cerebro humano sin ruido ni anomalías”.

En este trabajo se utiliza la modalidad T1 normal sin ruido, ni anomalías y el espesor por defecto, de la base de datos *BrainWeb: Simulated Brain Database* [*BrainWeb SBD*], como lo especifica la Sección 4.5, lo que justifica esta limitante.

Limitante 4. “Realizar el estudio comparativo utilizando imágenes digitales del cerebro humano en escala de grises”.

En este trabajo se utiliza la modalidad T1 de imágenes cerebrales en escala de grises, de la base de datos *BrainWeb: Simulated Brain Database* [*BrainWeb SBD*], como lo especifica la Sección 4.5, lo que justifica esta limitante.

Limitante 5. “El número de imágenes procesadas está limitado por el número de imágenes de la base de datos seleccionada, tomando en cuenta la capacidad del equipo de cómputo utilizado”.

Para este estudio se procesaron un número de 150 imágenes de la base de datos *BrainWeb: Simulated Brain Database [BrainWeb SBD]*, de la modalidad T1 (ver Sección 4.5), lo que justifica la limitante.

Limitante 6. “El tipo de métricas aplicadas, así como el tipo de algoritmos segmentadores utilizados en el estudio comparativo serán seleccionados exclusivamente por el comité de tesis, independientemente de los resultados que se obtengan”.

El comité correspondiente a este trabajo de tesis, en la presentación de avance intersemestral, considero la importancia de seleccionar las métricas y algoritmos adecuados para este proyecto de tesis, con lo cual se justifica la presente limitante.

Limitante 7. “El tiempo de procesamiento en este trabajo no es relevante”.

No se consideró el tiempo de procesamiento como relevante para este trabajo de tesis, con lo cual se justifica la presente limitante.

6.1.5. Metodología de solución

Para la concreción de este documento de tesis, se siguió la secuencia de etapas o fases propuestas en la Metodología de Solución dada en la Sección 1.10, lo cual se analiza como sigue:

Fase I. “Marco Teórico y Estado del Arte. Comprende el Estudio de los fundamentos biológicos y computacionales de las redes RNA tradicionales y Pulsantes, sobre todo, investigación del estado del arte de éstas últimas en el dominio de Visión Artificial en el área de segmentación de imágenes”.

En este trabajo de tesis se consideraron al Marco Teórico y al Estado del Arte partes fundamentales, dado que el primero proporciona una base o plataforma de conocimientos, que brindan seguridad y proporciona una perspectiva global en el cual se enmarca el problema en cuestión a dar solución, y el Estado del Arte nos brinda las herramientas para ahondar en el problema particular investigado. Por esta razón (ver Capítulo 3), se realizó, una investigación a conciencia del Modelo Neuronal Biológico, y de los dos Modelos fundamentales en todo estudio de Redes Neuronales Artificiales, que

son el Modelo Neuronal de McCulloch-Pitts, del cual se desprende todo el estudio de las Redes Neuronales Artificiales de primera y segunda generación, y el Modelo Neuronal de Hodgkin-Huxley, del cual se desprende todo el estudio de las Redes Neuronales Artificiales de la tercera generación, sin olvidar que el modelo de Hodgkin-Huxley fue el primer Modelo Neuronal Biológico, y que se erige como el modelo cuantitativo más exitoso en la ciencia neuronal, sino es que en toda la biología (Sección 3.4). El estudio realizado en los capítulos 2 y 3 justifican la presente fase del proyecto.

Fase II. “Desarrollo. Análisis y Desarrollo de la Red Neuronal Pulso-Acoplada en el campo de segmentación de imágenes”.

Como se menciona a inicios del Capítulo 4: Modelo Propuesto y Entorno de Experimentación, “El contenido de este capítulo comprende la fase II y parte de la fase III de la metodología de solución correspondiente a este trabajo”, y se verifica en las Secciones 4.1 a 4.4, lo que sustenta la presente fase.

Fase III. “Experimentación. Experimentar con la Red Neuronal Pulso-Acoplada con la base de datos de imágenes digitales del cerebro humano seleccionada previamente”.

En el Capítulo 4: Modelo Propuesto y Entorno de Experimentación, se menciona que, “El contenido de este capítulo comprende la fase II y parte de la fase III de la metodología de solución correspondiente a este trabajo”, y en el Capítulo 5: Experimentación y Resultados, se menciona que, “El contenido de este capítulo comprende la segunda parte de la fase III y la fase IV de la metodología de solución correspondiente a este trabajo”, en ambos capítulos se verifica la presente fase.

Fase IV. “Evaluación. Realizar Estudio Comparativo con los algoritmos segmentadores y métricas seleccionadas. Finaliza la fase con un Análisis de Resultados”.

Como se menciona y verifica en el Capítulo 5: Experimentación y Resultados, “El contenido de este capítulo comprende la segunda parte de la fase III y la fase IV de la metodología de solución correspondiente a este trabajo”, lo que sustenta la presente fase.

6.2. Aportaciones

En este trabajo se realiza una experimentación comparativa más amplia que la propuesta en Yide Ma [Ma, 2010], en la cual fue inspirado.

- El número de imágenes procesadas es comparativamente más grande.
- Se emplea como caso de estudio imágenes del cerebro humano
- Se realiza estudio comparativo con segmentadores diferentes de ICM.
- Se concluye que ICM es una alternativa competitiva para la segmentación

6.3. Productos y participaciones

En este apartado se exponen las actividades que contribuyeron tanto a la experimentación realizada para la concreción de objetivos, como a la parte formativa dentro del campo de la IA.

6.3.1. Presentación de Poster

Se elaboró poster titulado “Evaluación del Modelo Neuronal de Intersección Cortical para la Segmentación de Imágenes Médicas” que participó en la “2da Jornada de Ciencia y Tecnología Aplicada” organizada por el CENIDET los días 4 y 5 de Abril de 2019. En el Anexo A y B se presenta constancia de participación de este trabajo y evidencia.

6.3.2. Presentación de Artículo

Se realizó el artículo: “Segmentación Eficaz y Eficiente de Imágenes del Cerebro Humano mediante el Modelo Neuronal de Intersección Cortical” para el XV Congreso Internacional sobre Innovación y Desarrollo Tecnológico (CIINDET) 2019, ISBN CIINDET 2019 978-607-95255-9-0, del IEEE sección Morelos. Llevado a cabo del 2 al 4 de Octubre 2019, el cual se expuso el 3 de Octubre en la sede de las instalaciones del Hotel Holiday Inn de Cuernavaca Morelos, y del cual se entregó constancia que se presenta en el Anexo C.

6.3.3. Presentación de Artículo

Se realizó el artículo: “Modelo de Intersección Cortical como Alternativa Competitiva para la Segmentación de Imágenes Médicas”, que se expuso en la “Escuela de Inteligencia Computacional y Robótica”, SAIBOT 2019, llevada a cabo del 22 al 26 de Octubre, y que se expuso el 25 de Octubre en la sede ubicada en Cuernavaca Morelos, de la cual se entregó constancia, que se presenta en el Anexo D.

6.4. Conclusiones y trabajo futuro

- El estudio Comparativo realizado muestra que, utilizando imágenes cerebrales de la base de datos *BrainWeb*, ICM, de manera general, como procesador de imágenes, muestra mejor desempeño que los segmentadores: Canny, Sobel, *Watershed* (W) y *Linear Spectral Clustering* (LSC), bajo las métricas aplicadas: Entropía (H), Contraste del Nivel de Gris (GC), Entropía Cruzada (CE) que evalúan la mejor imagen segmentada, resultados reafirmados por la métrica (criterio) *Overall Merit* (OM).
- Una excepción en esta caso de estudio se presenta con el segmentador Sobel, el cual presenta un desempeño ligeramente mejor que ICM bajo la aplicación de la métrica Contraste del Nivel de Gris (GC), respecto a ICM según muestra la gráfica de la Figura 5.26.
- Desde una perspectiva cualitativa, visual subjetiva como la percibe cualquier persona humana, en muchos casos, las segmentaciones realizadas por el resto de los segmentadores, exceptuando a *Watershed*, presentan mejor calidad en la segmentación que ICM, como, por ejemplo, los casos de las Figuras 5.31, 5.32, y 5.42. En muchos otros casos, como, por ejemplo, las Figuras, 5.36, 5.37, 5.41 y 5.47, ICM presenta segmentaciones de calidad como el resto de segmentadores.
- Se debe trabajar más en la búsqueda de métricas que evalúen la mejor imagen segmentada de ICM, para que los resultados cuantitativos sean congruentes con las exigencias cualitativas subjetivas, dado que en general, ICM realiza

segmentaciones de calidad en bordes y regiones, y que pueden competir con las observadas por el resto de segmentadores, o bien, investigar diferentes sintonizaciones de los parámetros f, g, h de ICM aplicando las mismas métricas utilizadas en este trabajo que seleccionen la mejor imagen segmentada, dado que en este trabajo se utilizó un mismo conjunto de valores de f, g, h .

- En general, ICM se erige como una alternativa competitiva para la segmentación de imágenes digitales.
- La utilización de imágenes binarizadas en los segmentadores *Watershed* (H) y *Linear Spectral Clustering* (LSC), posiblemente no fue justa para ellos, que segmentan una imagen en grupos de superpíxeles.

Trabajo futuro.

- Investigar en la búsqueda de métricas que evalúen la mejor imagen segmentada de ICM, para que los resultados cuantitativos sean congruentes con las exigencias cualitativas subjetivas.
- Investigar en la búsqueda de diferentes conjuntos de valores de los parámetros f, g, h de ICM, aplicando las mismas métricas que evalúen la mejor imagen segmentada de ICM, de manera que los resultados cuantitativos sean congruentes con las exigencias cualitativas subjetivas. Los conjuntos de valores de f, g, h podrían ser diferentes para cada métrica empleada.

Bibliografía

- [Aguilar, 2019]** Aguilar K. S. Mejoramiento de la Luminosidad de Imágenes Digitales del Cerebro Humano mediante Redes Neuronales Pulso-Acopladas. Tesis de Maestría en Ciencias de la Computación, CENIDET. 2019.
- [Alhasanat, 2014]** Alhasanat A., Alashaary H., Matrouk K., Al-Qadi Z., Al-Shalabi H. (2014). "Experimental Investigation of Training Algorithms used in Backpropagation Artificial Neural Networks to Apply Curve Fitting", European Journal of Scientific Research ISSN 1450-216X / 1450-202X Vol.121 No.4, 2014, pp.328-335
- [Arbib, 1987]** Arbib, M.A., 1987. Brain, Machines and Mathematics, 2nd edition, Springer-Verlag.
- [Arbib, 2003]** Arbib, M.A., 2003. The handbook of brain theory and Neural Networks, 2nd edition, Massachusetts Institute of Technology.
- [Bear, 2016]** Bear M. F., Connors B. W., Paradiso M. A. (2016). "Neuroscience Exploring the Brain" fourth edition. Wolters Kluwer.
- [Beucher, 1993]** Beucher, S.; Meyer, F. The morphological approach to segmentation: The *watershed* transformation. In Mathematical Morphology in Image Processing; Marcel Dekker Inc. New York, NY, USA, 1993; Volume 34.
- [Bieniek, 2000]** Bieniek, A., Moga, A. An efficient *watershed* algorithm based on connected components. Pattern Recognit. **2000**, 33, 907–916.
- [Bo, 2008]** Xiao-Bo QU, Jing-Wen YAN, Hong-Zhi XIAO, and ZiQuian ZHU, "Image Fusion Algorithm Based on Spatial Frequency-Motivated Pulse Coupled Neural Networks in Nonsampled Contourlet Transform Domain", Acta Automatica Sinica, Vol. 34, No.12, December, 2008.
- [BrainWeb SBD]** <http://brainweb.bic.mni.mcgill.ca/brainweb/>, ultima visualización 03/02/2019.
- [Canny, 1983]** Canny J. F. "Finding edges and lines in images", M.I.T. Artif. Intell. Lab., Cambridge, MA, TR-720, 1983.
- [Canny, 1986]** Canny J. F. (1986). A Computational Approach to Edge Detection. IEEE transactions on pattern analysis and machine intelligence, vol. pami-8, no. 6, november 1986.

- [Cárdenas, 2014]** Cardenas S. Y. Pulse-Coupled Neural Networks applied to Human Brain Image Processing. 2014 International Conference on Mechatronics, Electronics and Automotive Engineering.
- [Cárdenas, 2015]** Cárdenas S. Y. Implementación y Evaluación de Redes Neuronales Artificiales tipo “Pulse-Coupled Neural Networks” (PCNN) Aplicadas a Visión Artificial. Tesis de Maestría en Ciencias de la Computación, CENIDET. 2014.
- [Charalambous, 1992]** Charalambous C. (1992) Conjugate gradient algorithm for efficient training of artificial neural networks, IEE G (Circuits, Devices and Systems), 139(3) (1992).
- [Churchland, 1986]** Churchland, P.S., and T.J. Sejnowski, 1992. The Computational Brain, Cambridge, MA: MIT Press.
- [Dayan-Abbott, 2001]** Dayan, P., and Abbott, L.F.: Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems. The MIT Press, Cambridge, Massachusetts, (2001).
- [Dhillon, 2007]** Dhillon I., Guan Y., Kulis Y. (2007). Weighted graph cuts without eigenvectors: a multilevel approach. IEEE Trans. on PAMI, 29(11):1944–1957, 2007.
- [Doborjeh, 2014]** Doborjeh Gholami, Capecci Elisa, Kasabov Nikola (2014). “Classification and Segmentation of fMRI Spatio-Temporal Brain Data with a NeuCube Evolving Spiking Neural Network Model”. Conference: Evolving and Autonomous Learning Systems (EALS), 2014 IEEE Symposium on, At Orlando, FL.
- [Eckhorn, 1989]** Eckhorn, R., Reitboeck, H. J., Arndt, M., and Dicke, P. **1989b**. “A neural network for feature linking via synchronous activity: Results from cat visual cortex and from simulations”, (1989). Neural Computation 2, 293-307
- [Eckhorn, 1990]** Eckhorn, R., Reitboeck, H. J., Arndt, M., and Dicke, P. 19890. “Feature Linking via Synchronization among Distributed Assemblies: Simulations of Results from Cat Visual Cortex”. Neural Computation **2**, **293-307** (1990)
- [Ekblad, 2004]** Ekblad U., Kinser J. M. “Theoretical foundation of the intersecting cortical model and its use for change detection of aircraft, cars, and nuclear explosion tests”. Signal Processing 84 (2004) 1131 – 1146

- [Gao, 2018]** Gao P., Li Z., Zhang H. “Thermodynamics-Based Evaluation of Various Improved Shannon Entropies for Configurational Information of Gray-Level Images”. *Entropy* 2018, 20, 19; doi:10.3390/e20010019
- [Gerstner-Kistler, 2002]** Gerstner, W. and Kistler, W. K. (2002) *Spiking Neuron Models: Single Neurons, Populations, Plasticity*. Cambridge University Press, Cambridge.
- [Gerstner-Kistler, 2014]** Gerstner, W. and Kistler, W. K. (2014) *Neuronal Dynamics: From Single Neurons to Networks and Models of Cognition*. Cambridge University Press, Cambridge.
- [Gonzalez, 2002]** Gonzalez R.C.: *Digital Image Processing*, 2nd Ed. Prentice Hall (2002)
- [Hagan, 1994]** Hagan, M. T., Menhaj M. B. (1994) Training feedforward networks with the Marquart algorithm, *IEEE Transactions on Neural Networks*, 5(6) 1994.
- [Hahn, 2003]** Hahn H. K., Peitgen H. (2003). IWT–Interactive *Watershed* Transform: A hierarchical method for efficient interactive and automated segmentation of multidimensional grayscale images. *Proc. Medical Imaging, SPIE 5032*.
- [Hahn, 2005]** Hahn H. K. (2005). *Morphological Volumetry, Theory, Concepts and Application to Quantitative Medical Imaging*. MeVis-Center for Medical Diagnostic System and Visualization. University of Bremen 2005.
- [Hassabis, 2017]** Hassabis D., Kumaran D., Summerfield C., Botvinick K. (2017) *Neuroscience-Inspired Artificial Intelligence*. *Neuron* 95. 2017 Published by Elsevier Inc.
- [Haykin, 1999]** Haykin, Simon (1999). *Neural Networks: A Comprehensive Foundation*, Prentice Hall, New Jersey, 1999.
- [Haykin,2009]** Haykin, Simon. *Neural Networks and Learning Machines*. Vol.3. Upper Saddle River, NJ, USA. Pearson, 2009.
- [Hernández, 2016]** Hernández Becerra C., Mejía Lavallo M. Clasificación de patrones mediante el uso de una red neuronal pulsante. *Congreso Mexicano de Inteligencia Artificial 2016*, vol 5.
- [Hernández, 2017]** Hernández Becerra C. Aplicación del Descenso de Gradiente para el Aprendizaje de Neuronas Pulsantes de Izhikevich. Tesis de Maestría en Ciencias de la Computación, CENIDET. 2017

- [Hertz, 1991]** Hertz J., Krogh A., Palmer R. G (1991), "Introduction to the theory of neural computation", Santa Fe Institute Studies in the Sciences of Complexity. CRC Press Taylor & Francis Group.
- [Hill, 1936]** Hill, A. (1936) Excitation and accommodation in nerve. Proc. R. Soc. Lond. B, 119:305–355.
- [Hodkin-Huxley, 1939]** Hodgkin AL, Huxley AF. 1939. Action potentials recorded from inside a nerve Fiber. Nature 144:710–711.
- [Hodkin-Huxley, 1952]** Hodgkin A. L., Huxley A. F. (1952). A Quantitative Description of Membrane Current and its Application to Conduction and Excitation in Nerve. J. Physiol. (1952) 117, 500-544
- [Hu, 2015]** Hu Zhongwen, Zou Qin. (2015). *Watershed* Superpixel. Conference Paper, September 2015.
- [Ilonen, 2003]** Ilonen J., Kamarainen J. I., Lampinen J. "Differential Evolution Training Algorithm for Feed-Forward Neural Networks". Neural Processing Letters 17: 93–105,2003. # 2003 Kluwer Academic Publishers. Printed in the Netherlands.
- [Izhikevich, 2000]** Izhikevich E. M. (2007) Neural Excitability, Spiking and Bursting. International Journal of Bifurcation and Chaos, Vol. 10, No. 6 (2000) 1171{1266
- [Izhikevich, 2003]** Izhikevich E. M. (2003) Simple Model of Spiking Neurons. IEEE Transactions On Neural Networks, Vol. 146, pp. 1569-1572, Noviembre 2003.
- [Izhikevich, 2004]** Izhikevich E. M. (2004) Which Model to Use for Cortical Spiking Neurons? IEEE Transactions on Neural Networks, Vol. 155, pp. 1063-1069, Septiembre 2004.
- [Izhikevich, 2007]** Izhikevich E. M. (2007) Dynamical Systems in Neuroscience: The Geometry of Excitability and Bursting. QP363.3.I94 2007 573.8'01'13. DC21
- [Kandel, 2001]** Kandel E. R., Schwartz J. H., Jessell T. M. (2000) Principles of Neural Science. Fifth Edition. The McGraw-Hill Companies 2000.
- [Kandel, 2007]** Kandel, Eric R. (2007), In Search of Memory: The Emergence of a New Science of Mind, New York: W. W. Norton & Company, ISBN 978-0-393-32937-7.

- [Kandel, 2013]** Kandel E. R., Schwartz J. H., Jessell T. M., Siegelbaum S. A., Hudspeth A. J. (2013) Principles of Neural Science. Fifth Edition. The McGraw-Hill Companies 2013.
- [Kiernan, 2014]** Kiernan J.A., N. Rajakumar (2014). Barr's The Human Nervous System: An Anatomical Viewpoint, 10th Ed. Lippincott Williams & Wilkins, a Wolters Kluwer business.
- [Kinser, 2004]** Kinser M. J., Wang Guisong, Texture recognition of medical images with the ICM method, Nuclear Instruments and Methods in Physics Research A 525, 387-391, 2004
- [Kleene, 1956]** Kleene, S. C. (1956). 'Representation of Events in Nerve Nets and Finite Automata, in C. E. Shannon and J. McCarthy (eds.), Automata Studies, Princeton University Press, Princeton, NJ.
- [Kornilov, 2018]** Kornilov Anton S., Safonov Iliia V. (2018). "An Overview of Watershed Algorithm Implementations in Open Source Libraries", Journal of Imaging, Vol. 4, Issue. 123, pp. 1-15, doi:10.3390/jimaging4100123
- [Krig, 2016]** Krig S. (2016). Computer vision metrics, survey, taxonomy and analysis. Apress 2016
- [Kurmasha, 2017]** Kurmasha (2017). Enhancement of Edge-based Image Quality Measures Using Entropy for Histogram Equalization-based Contrast Enhancement Techniques. Engineering, Technology & Applied Science Research Vol. 7, No. 6, 2017, 2277-2281.
- [Lapicque, 1907]** Lapicque Louis (1907). Quantitative investigations of electrical nerve excitation treated as polarization. Biological Cybernetics · December 2007. DOI: 10.1007/s00422-007-0189-6
- [Lee, 2017]** Lee Eun-Jae, Kim Yong-Hwan, Kim Namkug, Kang Dong-Wha, 2017. Deep into the Brain: Artificial Intelligence in Stroke Imaging. Journal of Stroke 2017;19(3):277-285
- [Li&Chen, 2015]** Li, Z., Chen, J. (2015). Superpixel segmentation using linear spectral clustering. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pages 1356–1363.
- [Lian, 2019]** Lian J., Yang Z., Liu J., Sun W., Zheng Li, Du X., Yi Z., Shi B., Ma Y. "An Overview of Image Segmentation Based on Pulse-Coupled Neural Network". Archives of Computational Methods in Engineering <https://doi.org/10.1007/s11831-019-09381-5>.

- [Lindblad, 2005]** Lindblad T., Kinser J. M., Image Processing Using Pulse-coupled Neural Networks. Springer, 2005
- [Liu M-Y, 2001]** Liu M.Y., Tuzel O., Ramalingam S., Chellappa R. (2011). Entropy rate superpixel segmentation. Technical report, University of Maryland College Park, 2011. TR2011-035
- [Ma ,2002]** MA Yi-de, DAI Ruo-lan. (2002). Automated image segmentation using pulse coupled neural networks and image entropy. Journal of China Institute of Communications, 2002,23(1):46~50
- [Ma, 2004]** MA Yi-de, LIU Qing, QIAN Zhi-bai. (2004). Automated image segmentation using improved PCNN model based on crossentropy. Conference Paper · November 2004 DOI: 10.1109/ISIMP.2004.1434171 · Source: IEEE Xplore
- [Ma, 2010]** Ma Y., Zhan K., Wang Z. (2010). Applications of Pulse-Coupled Neural Networks. Springer, 2010, pp. 11–25.
- [Mass, 1997]** Maass W. (1997). Networks of Spiking Neurons: The Third Generation of Neural Network Models. Institute for Theoretical Computer Science. Technische Universitit Graz, NeuralNetworks, Vol. 10, No. 9, pp. 1659-1671, 1997
- [Matadamas,2014]** Matadamas I. C. Aplicación de las RNP en el reconocimiento de Patrones y Análisis de imágenes. Tesis de Maestría, Instituto Politécnico Nacional, Centro de Investigación en Computación, México, D.F.
- [McCulloch-Pitts, 1943]** McCulloch, W. S. and W. H. Pitts: 1943, "A Logical Calculus of the Ideas Immanent in Nervous Activity", Bulletin of Mathematical Biology Vol. 52, No. 1/2. pp. 99-115. 1990. Printed in Great Britain.
- [Minsky, 1967]** Minsky, M.L. (1967). Computation: Finite and Infinite Machines. Englewood CHffs, NJ: Prentice-Hall.
- [Morales, 2018]** Morales X. M. Segmentación no Paramétrica de Tejidos Cerebrales Mediante una Arquitectura Paralela de Redes Neuronales Convolucionales. Tesis de Maestría en Ciencias de la Computación, CENIDET. 2018.
- [Nwankpa, 2018]** Nwankpa C. E., Ijomah W., Gachagan A., Marshall S., "Activation Functions: Comparison of Trends in Practice and Research for Deep Learning". Available: arXiv:1811.03378v1 [cs.LG] , 2018 .

- [Ortiz, 2016]** Ortiz, E., Mejía-Lavalle, M., & Sossa, H. “Uso de redes neuronales pulsantes para mejorar el filtrado de imágenes contaminadas con ruido Gaussiano.” *Research in Computing Science*, 114, 45–58. 2016.
- [Ortiz, 2017]** Ortiz, E. Detección de Ruido Impulsivo o Gaussiano en Imágenes Monocromáticas Mediante Redes Neuronales Artificiales Pulso-Acopladas. Tesis de Maestría en Ciencias de la Computación, CENIDET. 2017.
- [Osawa, 2015]** Osawa, Yoshika, Takashi Kohno. Associative Memory with Class I and II Izhikevich Model. The International Conference on Artificial Life and Robotics. (2015).
- [Piccinini, 2004]** Piccinini, Gualtiero (2004). “The First Computational Theory of Mind and Brain: A Close Look at Mcculloch and Pitts’s ‘Logical Calculus of Ideas Immanent in Nervous Activity.’” *Synthese* 141 (2004): 175–215.
- [Ramírez, 2011]** Ramírez Juan A. y Chacón Mario I. “Redes neuronales artificiales para el procesamiento de imágenes, una revisión de la última década”, RIEE & C, revista de Ingeniería Eléctrica, Electrónica y Computación, vol. 9 no. 1, Julio 2011.
- [Ranganath, 1995]** Ranganath H. S., Kuntimad G., Johnson J. L. (1995). “Pulse Coupled Neural Networks for Image processing”, In *Proceeding IEEE Southeastcon*, Raleigh, NC, 1995.
- [Rojas, 2001]** Rojas R. *Neural Networks - A Systematic Introduction*, Springer-Verlag, Berlin, New-York, 1996.
- [Serra, 1982]** Serra, J. *Image Analysis and Mathematical Morphology*; Academic Press: New York, NY, USA, 1982.
- [Shapshak, 2018]** Shapshak P. (2018) Artificial Intelligence and brain. *Bioinformation*. January 2018 DOI: 10.6026/97320630014038
- [Sobel, 2014]** Sobel Irwin, An Isotropic 3x3 (1968). Image Gradient Operator. Documentado: February 2014.
- [Stutz, 2017]** Stutz D., Hermans A., Leibe B. (2017). “Superpixels: An Evaluation of the State-of-the-Art”. arXiv:1612.01601v3 [cs.CV] 19 Apr 2017

- [Taha, 2014]** Taha A. A., Hanbury A., Jimenez del Toro O. (2014). "A Formal Method for Selecting Evaluation Metrics for Image Segmentation" Conference Paper. 2014 DOI: 10.1109/ICIP.2014.7025187
- [Thakur, 2009]** Thakur A., Bhanot S., Mishra S. N., (2009). "Early Diagnosis of Ischemia Stroke using Neural Network". Proceedings of the International Conference on Man-Machine Systems (ICoMMS) 11 – 13 October 2009, Batu Ferringhi, Penang, MALAYSIA
- [Tsai, 2008]** Tsai Du-Yih. (2008). Information-Entropy Measure for Evaluation of Image Quality Journal of Digital Imaging, Vol 0, No 0 (Month), 2008: pp 1Y10
- [Vincent, 1991]** Vincent, L., Soille, P. (1991). Watersheds in digital spaces: An efficient algorithm based on immersion simulations. IEEE Trans. Patt. Anal. Mach. Intell. 1991, 13, 583–598.
- [Wang, 2010]** Wang Z., Ma Y., Cheng F., Yang L. (2010). "Review of pulse-coupled neural networks". Image and Vision Computing, 2010 Elsevier B.V. All rights reserved.
- [Weili, 2009]** Weili S., Yu M., Zhanfang C., Hongbiao Z. (2009). Research of Automatic Medical Image Segmentation Algorithm Based on Tsallis Entropy and Improved PCNN. Proceedings of the 2009 IEEE International Conference on Mechatronics and Automation. August 9 - 12, Changchun, China
- [Yang, 2015]** Yang J., Zhang P., Liu Y. (2015). Robustness of classification ability of spiking neural networks. Nonlinear Dynamics 82.1-2 (2015): 723-730.
- [Zarate, 2016]** Zarate M. B. Extracción de Características de Imágenes Digitales mediante una Red Neuronal Artificial Pulsante. Tesis de Maestría en Ciencias de la Computación, CENIDET. 2014.
- [Zhan, 2016]** Zhan K, Shi J, Wang H, Xie Y, Li Qi, (2016) Computational Mechanisms of Pulse-Coupled Neural Networks: A Comprehensive Review. Arch Computat Methods Eng (2017) 24:573–588 DOI 10.1007/s11831-016-9182-3

Anexos

Anexo A. Constancia Poster: Jornada de Ciencia, Tecnología e Innovación Tecnológica 2019.



**EL TECNOLÓGICO NACIONAL DE MÉXICO
A TRAVÉS DEL CENTRO NACIONAL DE INVESTIGACIÓN
Y DESARROLLO TECNOLÓGICO**

OTORGAN LA PRESENTE

CONSTANCIA

A

José Luis Soto Piña, Manuel Mejía Lavalle

POR SU PARTICIPACIÓN CON EL POSTER: "EVALUACIÓN DEL
MODELO NEURONAL DE INTERSECCIÓN CORTICAL
PARA LA SEGMENTACIÓN DE IMÁGENES MÉDICAS",
PRESENTADO EN LA SEGUNDA JORNADA DE CIENCIA Y
TECNOLOGÍA APLICADA, QUE SE LLEVO A CABO LOS DÍAS 4 Y 5
DE ABRIL DE 2019, EN LA CIUDAD DE CUERNAVACA, MORELOS,
MÉXICO.

CUERNAVACA, MOR., A 5 DE ABRIL DE 2019.

DR. VÍCTOR HUGO OLIVARES PEREGRINO
DIRECTOR



Anexo B. Poster: Jornada de Ciencia, Tecnología e Innovación Tecnológica 2019

Evaluación del Modelo Neuronal de Intersección Cortical para la Segmentación de Imágenes Médicas

José Luis Soto Piña
Asesor: Dr. Manuel Mejía Lavalle



TECNM
Centro Nacional de Investigación y Desarrollo Tecnológico



cenidet
Centro Nacional de Investigación y Desarrollo Tecnológico

(jose.soto18ca, mjavalle)@cenidet.edu.mx

Motivación

- La mayoría de las técnicas para detectar bordes utilizan operadores locales sustentados en aproximaciones locales de la primera y segunda derivada de los niveles de gris de la imagen, basadas en cálculos matemáticos.
- La variante del paradigma de Red Neuronal Puls Acoplada (PChN), llamado Modelo de Intersección Cortical (ICM), se puede utilizar de manera natural para tratar el problema de segmentación de imágenes mediante detección de bordes [Correas,2014].
- Se propone el modelo ICM, como método alternativo, para dar solución al problema de segmentación de imágenes.

Problemática

- La segmentación de imágenes es el proceso mediante el cual una imagen es dividida en sus partes constituyentes de acuerdo con sus atributos, como la intensidad de cada pixel, valores espectrales o sus propiedades de textura [Ma, 2011].
- Diversas técnicas se han utilizado para dar solución al problema de segmentación de imágenes y el más simple y efectivo es el método basado en el umbral de nivel de gris, pero es muy difícil seleccionar un umbral apropiado [Ma, 2011].
- Se propone el modelo ICM (ver Fig. 1) debido a que es un paradigma más cercano al modelo biológico del cerebro [Luvitani, 2005].
- ICM genera una serie de imágenes binarias (una imagen por cada época) que son variaciones de una imagen original en tonos de gris y que son resultado de efectos "auto-onda" de las redes PChN (ver Fig. 2).

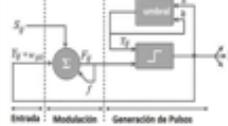


Figura 1. El modelo ICM [Orta, 2017]



Figura 2. Salidas de una Red Pulsante para nueve épocas (efecto "auto-onda") [Ma, 2011].

Para una selección apropiada de la mejor imagen segmentada se emplean las métricas de la Entropía y Contraste del Nivel de Gris (ecuaciones 1 y 2 respectivamente). Se comparan los resultados de ICM contra los resultados del método Canny (ecuaciones 3 a 5).

$$H(x) = -\sum_{i=1}^n p_i \log_2 p_i \quad (1)$$

$$GC = \sqrt{I_x - I_y} / \sqrt{I_x + I_y} \quad (2)$$

Método Canny

$$K = \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 8 & 12 & 8 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 8 & 12 & 8 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix} \quad (3)$$

Fase para encontrar la intensidad del gradiente aplicando máscaras de convolución en x, y.

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (4) \quad G_y = \begin{bmatrix} -1 & 1 & 1 \\ -2 & 2 & 2 \\ -1 & 1 & 1 \end{bmatrix} \quad (5) \quad G = \sqrt{G_x^2 + G_y^2} \quad (6)$$

Fase para encontrar la dirección del gradiente

$$\theta = \tan^{-1} \left(\frac{G_y}{G_x} \right) \quad (7)$$

Resultados

Se fijaron los valores de los parámetros de ICM como sigue: $r = 0.19$, $g = 0.89$ y $h = 14.5$, y un total de 40 épocas. Se utilizó una imagen digital (Figura 3) de Razonamiento Matemático (RM) a la cual se le aplicaron las métricas de H y GC. Las Gráficas correspondientes con la 1 y la 2. Se muestran en las Figuras 4 y 5 las imágenes seleccionadas de acuerdo al mejor resultado de estas dos métricas. En ambas Gráficas podemos observar la comparativa con el método Canny.



Figura 3. Imagen médica original



Figura 4. Imagen seleccionada mediante la Entropía



Figura 5. Imagen seleccionada mediante GC



Gráfico 1. Entropía de las imágenes de salida. La entropía máxima es de 5.166717 y ocurre en la época 21.

Gráfico 2. Valor de la métrica GC de las imágenes de salida. El contraste máximo es de 0.571629 y ocurre en la época 21.

Objetivo

- Implementar y experimentar con la variante de la PChN llamado Modelo de Intersección Cortical (ICM) para la segmentación de imágenes digitales del cerebro humano, evaluado con las métricas del Contraste del Nivel de Gris (GC) y de la Entropía (H).

Propuesta de solución

Inicio

Leechas de imágenes de entrada (segmentación de un objeto binario) y datos parámetros: intensidad de ICM

Introducción de píxeles de la imagen de entrada para configurar el modelo de la Red Neuronal ICM.

Aplicación de la rutina generada de modulación a la cada píxel para medir la entrada binaria: vector \rightarrow IN

Calculo del $H(x)$ y GC de la salida Y

Fin

Inicio de ciclo
¿ $P > T$ (límite)?
Si, se termina
Si no, se repite

Actualización del estado y de valores de las variables involucradas y actualización de los puntos de salida
Generación del pulso V sigue
Selección de la imagen de salida de acuerdo a las métricas H y GC

Conclusión

- Se implementó el Modelo de Intersección Cortical pulsanete ICM para la segmentación de imágenes digitales del cerebro humano, evaluado con las Métricas del Contraste del Nivel de Gris y de la Entropía.
- ICM se comporta 7% mejor en entropía y 5% mejor en GC que Canny.
- La ventaja de ICM es que, al tener un proceso paralelo, es más eficiente T/Número de pixels donde T es el tiempo de Canny.

Referencias

[Ma, 2011] S. Ma, K. Zhou, Z. Wang, *Applications of pulse-coupled neural networks*, Springer, 2011.

[Orta, 2017] Estela Orta Puiguel, Manuel Mejía-Lavalle y Humberto Socod, "Método de ruido baseados en redes neuronales pulsoacopladas", 3-Centro Nacional de Investigación y Desarrollo Tecnológico, Departamento de Ciencia, Computaciónes, Comunicación, México, México 2) Instituto Politécnico Nacional, Centro de Investigación en Computación, Ciudad de México, México, 2017

[Correas, 2014] Selene Yacovitch Correas, Manuel Mejía-Lavalle, Humberto Socod Avellan, Felipe Caldeiro "PChN" Departamento de Ciencia, Computaciónes, (ICM2017), México Instituto Politécnico Nacional, México" Universidad Ben José Carlos, España, 2014.

[Luvitani, 2005] Luciano T. Sator 2-M: Imageprocessing using pulse-coupled neural networks. In: Springer, Jul. 2005

Anexo C. Constancia Artículo CIINDET 2019



Anexo D. Evidencia Artículo CIINET 2019

XV Congreso Internacional sobre Innovación y Desarrollo Tecnológico,
2 al 4 de octubre de 2019, Cuernavaca Morelos, México.

Segmentación Eficaz y Eficiente de Imágenes del Cerebro Humano mediante el Modelo Neuronal de Intersección Cortical

J.L. SOTO-PIÑA, M. MEJÍA-LAVALLE, K.S. AGUILAR-DOMINGUEZ, J. RUIZ, G. REYES

Tecnológico Nacional de México/CENIDET
{jose.soto18ca_mlavalle, kevin.aguilar17ca, josera, greyes}@cenidet.edu.mx

Resumen— El modelo de Red Neuronal Pulso-Acoplada inspirado en estudios de la corteza visual de mamíferos, ha mostrado una adaptación natural para segmentación de imágenes debido a su naturaleza pulsante, lo que lo acerca más al modelo neuronal biológico. En un mundo donde la mayoría de las técnicas para segmentar y/o detectar bordes utilizan operadores locales sustentados en aproximaciones discretas de la primera y segunda derivada de los niveles de gris de la imagen, se propone el modelo ICM para dar solución al problema de segmentación de imágenes. En este trabajo se experimenta con la Red Neuronal de Intersección Cortical ICM (una de las variantes de las Redes Neuronales Pulso-Acopladas PCNN), como una alternativa para la segmentación de imágenes del cerebro humano, con utilización de las métricas del Contraste del Nivel de Gris y de la Entropía para la evaluación de la segmentación, y se hizo una comparativa con la técnica clásica Canny, contra la cual la ICM fue mejor en un 30%.

Palabras clave. Segmentación de imágenes, Redes Neuronales Pulso-Acopladas, Modelo de Intersección Cortical, Canny.

1. Introducción

En este trabajo se emplea la Red Neuronal de Intersección Cortical ICM, como un método alterno para dar solución al problema de segmentación de imágenes. Su procesamiento paralelo, y debido a que es un paradigma cercano al modelo biológico, la hacen adaptarse de manera natural al procesamiento de imágenes. Como toda PCNN, la ICM genera una serie de imágenes binarias (debido al efecto auto-onda de la red), una imagen por cada época, que son variaciones de una imagen original. Para realizar una evaluación de la mejor imagen segmentada, se aplican dos criterios de evaluación o métricas: la Métrica del Contraste del Nivel de Gris (GC), y la Entropía (H), y se realiza una comparativa con el método clásico de Canny. La organización del trabajo es el siguiente: A manera de ubicación, primero se tratan los temas de Segmentación y RNA de manera general, seguido del tema de las PCNN y de la ICM. Posteriormente se da una explicación de la experimentación realizada, se incluye una Discusión de Resultados y finalmente se dan las conclusiones y el trabajo futuro.

2. Marco Conceptual

La siguiente Sección tiene la finalidad de ubicar al lector sobre los fundamentos teóricos involucrados.

A. Segmentación

La segmentación de imágenes es el proceso mediante el cual, una imagen es dividida en sus partes constituyentes de acuerdo con sus atributos, como la intensidad de cada pixel, valores espectrales o sus propiedades de textura obteniéndose las regiones más sobresalientes [1]. Separar los objetos del fondo de una imagen mediante binarización, es el proceso básico de la segmentación, lo cual es utilizado para la clasificación y reconocimiento de objetos en diferentes campos de la visión artificial (Fig. 1). La segmentación por detección de bordes, generalmente se realiza por métodos basados en operadores locales sustentados en aproximaciones de la primera y segunda derivada, lo que requiere de cálculos matemáticos laboriosos. Entre las técnicas que se han utilizado para dar solución al problema de segmentación, el más simple y efectivo es el basado en la determinación del umbral del nivel de gris, pero es muy difícil seleccionar un umbral apropiado [1].

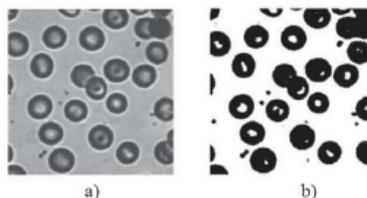


Figura 1. Ejemplo de Segmentación. a) Imagen original, b) Imagen Segmentada [1].

B. Redes Neuronales Artificiales

De manera general [2][3], las Redes Neuronales Artificiales, son modelos matemáticos procesadores de información, que emulan el sistema nervioso de los organismos vivos. Son adaptables, dado que responden a cambios estructurales en el proceso de generación de datos. La arquitectura típica de una Red Neuronal está conformada por una serie de unidades llamadas nodos, células o neuronas, organizadas en capas, e interconectadas de acuerdo con una

Anexo D. Reconocimiento Ponencia Artículo Escuela de Inteligencia Artificial y Robótica (SAIBOT 2019).



Anexo E. Evidencia Artículo SAIBOT 2019

Modelo de Intersección Cortical como Alternativa Competitiva para la Segmentación de Imágenes Médicas

J.L. Soto Piña, M. Mejía Lavalle, K.S. Aguilar Domínguez, J. Ruiz y G. Reyes

Tecnológico Nacional de México/CENIDET

Cuernavaca Morelos, Mex.

{jose.soto18ca, mlavalle, kevin.aguilar17ca, josera y greyes}@cenidet.edu.mx

Resumen— El modelo de Red Neuronal Pulso-Acoplada inspirado en estudios de la corteza visual de mamíferos, ha mostrado una adaptación natural para segmentación de imágenes debido a su naturaleza pulsante, lo que lo acerca más al modelo neuronal biológico. En un mundo donde la mayoría de las técnicas para segmentar y/o detectar bordes utilizan operadores locales sustentados en aproximaciones discretas de la primera y segunda derivada de los niveles de gris de la imagen, se propone el modelo ICM para dar solución al problema de segmentación de imágenes. En este trabajo se experimenta con la Red Neuronal de Intersección Cortical ICM (una de las variantes de las Redes Neuronales Pulso-Acopladas PCNN), como una alternativa para la segmentación de imágenes del cerebro humano, con utilización de la métrica del Contraste del Nivel de Gris para la evaluación de la segmentación, y se hizo una comparativa con la técnica clásica Canny, contra la cual la ICM fue mejor en un 30%, mostrando también que esta última compete en calidad de resultado y velocidad al ser comparada contra Canny.

Palabras clave. Segmentación de imágenes, Redes Neuronales Pulso-Acopladas, Modelo de Intersección Cortical, Canny.

I. INTRODUCCIÓN-MOTIVACIÓN

En este trabajo se emplea la Red Neuronal de Intersección Cortical ICM, como un método alternativo para dar solución al problema de segmentación de imágenes. Su procesamiento paralelo, y debido a que es un paradigma cercano al modelo biológico, la hacen adaptarse de manera natural al procesamiento de imágenes. Como toda PCNN, la ICM genera una serie de imágenes binarias (debido al efecto auto-onda de la red), una imagen por cada época, que son variaciones de una imagen original. Para realizar una evaluación de la mejor imagen segmentada, se aplica un criterio de evaluación o métrica: la Métrica del Contraste del Nivel de Gris (GC), y se realiza una comparativa con el método clásico de Canny. La organización del trabajo es el siguiente: A manera de ubicación, primero se tratan los temas de Segmentación y RNA tradicionales de manera general, seguido del tema de las PCNN y de la ICM. Posteriormente se da una explicación de la experimentación realizada, se incluye una Discusión de Resultados y finalmente se dan las Conclusiones y el Trabajo Futuro.

II. ELEMENTOS CLAVE

Esta Sección tiene la finalidad de ubicar al lector sobre los fundamentos teóricos involucrados.

A. Bordes, Regiones y Segmentación

La segmentación de imágenes es el proceso mediante el cual, una imagen es dividida en sus partes constituyentes de acuerdo con sus atributos, como la intensidad de cada píxel, valores espectrales o sus propiedades de textura obteniéndose

las regiones más sobresalientes [1]. Separar los objetos del fondo de una imagen mediante binarización, es el proceso básico de la segmentación, lo cual es utilizado para la clasificación y reconocimiento de objetos en diferentes campos de la visión artificial (Fig. 1). La segmentación por detección de bordes, generalmente se realiza por métodos basados en operadores locales sustentados en aproximaciones de la primera y segunda derivada, lo que requiere de cálculos matemáticos laboriosos. Entre las técnicas que se han utilizado para dar solución al problema de segmentación, el más simple y efectivo es el basado en la determinación del umbral del nivel de gris, pero es muy difícil seleccionar un umbral apropiado [1].

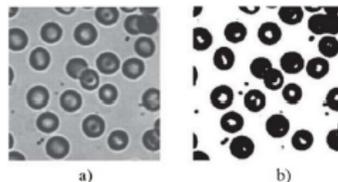


Fig. 1 Ejemplo de Segmentación.
a) Imagen original, b) Imagen Segmentada [1].

B. Redes Neuronales Tradicionales

De manera general [2][3], las Redes Neuronales Artificiales, son modelos matemáticos procesadores de información, que emulan el sistema nervioso de los organismos vivos. Son adaptables, dado que responden a cambios estructurales en el proceso de generación de datos. La arquitectura típica de una Red Neuronal está conformada por una serie de unidades llamadas nodos, células o neuronas, organizadas en capas, e interconectadas de acuerdo con una arquitectura particular, dependiendo del propósito de la misma. Cada nodo en sí es un procesador que recibe una señal de entrada y emite una señal de salida hacia otros nodos. La red consta de dos capas externas, una de entrada de datos, una de salida, y una o más capas intermedias llamadas capas ocultas. A cada conexión entre dos nodos se le asigna un "peso", o ponderación, que es la información actual de ese nodo necesaria para realizar una acción, dependiendo de la excitación, o señal de entrada. La tarea de la Red es autoajustar los pesos sinápticos mediante un algoritmo de aprendizaje inherente, para cumplir con su propósito de manera óptima (ver Fig. 2). Las Redes Neuronales anteriores corresponden a la llamada segunda generación que se caracterizan por aplicar una función de