

Centro Nacional de Investigación y Desarrollo Tecnológico

Subdirección Académica

Departamento de Ciencias Computacionales

TESIS DE MAESTRÍA EN CIENCIAS

**Extracción de Descripciones de Imágenes Digitales Mediante una Red
Neuronal Artificial Pulsante**

presentada por

Ing. Mario Bismarck Zarate Galindo

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

Director de tesis
Dr. Manuel Mejía Lavalle

Cuernavaca, Morelos, México. Enero de 2016.

"2015, Año del Generalísimo José María Morelos y Pavón"

Cuernavaca, Mor., 17/diciembre/2015
OFICIO No. DCC/264/2015

Asunto: Aceptación de documento de tesis

C. DR. GERARDO V. GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial del **C. Mario Bismarck Zárate Galindo**, con número de control M13CE065, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis profesional titulado "**Extracción de Descripciones de Imágenes Digitales mediante una Red Neuronal Artificial Pulsante**" y hemos encontrado que se han realizado todas las correcciones y observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

DIRECTOR DE TESIS



Dr. Manuel Mejía Lavallo
Doctor en Ciencias Computacionales
8342472

REVISOR 1



Dr. Raúl Pinto Arias
Doctor en Ciencias en la Especialidad de Ingeniería
Eléctrica
3890453

REVISOR 2



Dr. José Ruiz Ascencio
Doctor en Ciencias
5009035

REVISOR 3



Dr. Dante Mújica Vargas
Doctor en Comunicaciones y Electrónica
09131756

C.p. Lic. Guadalupe Garrido Rivera - Jefa del Departamento de Servicios Escolares.
Estudiante
Expediente
AMR/Imz



Cuernavaca, Mor., 14 de enero de 2016
OFICIO No. SAC/028/2016

Asunto: Autorización de impresión de tesis

ING. MARIO BISMARCK ZÁRATE GALINDO
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 "**Extracción de Descripciones de Imágenes Digitales Mediante una Red Neuronal Artificial Pulsante**", 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

"CONOCIMIENTO Y TECNOLOGÍA AL SERVICIO DE MÉXICO"

DR. GERARDO VICENTE GUERRERO RAMÍREZ
SUBDIRECTOR ACADÉMICO



CENTRO NACIONAL DE
INVESTIGACIÓN Y
DESARROLLO
TECNOLÓGICO
SUBDIRECCIÓN
ACADÉMICA

C.p. Lic. Guadalupe Garrido Rivera.- Jefa del Departamento de Servicios Escolares.
Expediente

GVGR/mcr



Dedicatoria.

*Para mis padres, hermanos
Namaste*

Agradecimientos

Agradezco al Consejo Nacional de Ciencia y Tecnología (CONACYT) y al Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) por permitirme realizar mis estudios de maestría y proporcionarme las herramientas necesarias para cumplir con esta meta.

A mi director de Tesis el Dr. Manuel Mejía Lavalle, director de esta tesis por su tiempo, paciencia y orientación a lo largo de esta investigación.

A los revisores de tesis, Doctor José Ruiz Ascencio, Doctor Raúl Pinto Elías y Doctor. Dante Mujica Vargas por sus observaciones, comentarios y sugerencias para el mejoramiento de la calidad de esta tesis.

A mis padres América Galindo y Mario Zarate por su amor y apoyo incondicional, estar en cada paso de mi vida. Gracias por su apoyo moral y económico.

A mis hermanos Itzel, Dafne y Andrés por el soporte moral recibido, especialmente Andrés por la ayuda en soporte técnico y documentación.

A mis profesores de vida Lic. Gabriel García del que he recibido un apoyo incondicional y Mtro. Daniel Mulato por los consejos acertados.

A los que aportaron su tiempo y espacio en conseguir algún artículo, libro, software y en la aportación de ideas, gracias: Selene Cárdenas, Alma Alheli Pedro Pérez, Guadalupe López Ortega, Rita Alejandra, Alida Esmeralda Zarate Jiménez, Omar Guzmán Ruiz, Juan José Rosas Varela,

Asimismo, un agradecimiento especial a aquellos que participaron de alguna manera directa o indirectamente mis amigos Juan Miranda, Juan Mortiz, Balam Lujan, Holkan Lujan, Miguel Bravo, Alejandro Galindo.

Resumen

Este documento de tesis presenta un método para obtener descriptores globales (características) de una imagen digital, los cuales sirven para obtener una “Firma” o huella de una imagen digital. Las “Firmas” fueron obtenidas con tres paradigmas pulsantes, se analizó el comportamiento de las “Firmas” de imágenes con distintos tipos de transformación en rotación, escalado, ruido impulsivo y ruido aditivo. El objetivo es distinguir si las “Firmas” obtenidas son invariantes a los distintos tipos de transformación de la imagen o si las “Firmas” son variantes entre imágenes distintas.

Para esta investigación se seleccionó el paradigma pulsante PCNN(*Pulse Couple Neuronal Network*) y dos de sus variantes ICM (*Intersection Cortical Model*) y SCM (*Spiking Cortical Model*), utilizados para extraer características de las imágenes digitales. Se experimentó con descripciones o "Firmas" de una imagen digital obtenidas de la aplicación sucesiva de una red neuronal pulsante, para obtener una serie de imágenes derivadas. Por medio del conteo del número de bits en imágenes binarias pulsantes se obtiene una serie de tiempo que se hipotetiza para describir la imagen.

Las pruebas realizadas en esta tesis se llevaron a cabo de nueve distintas maneras para obtener una “Firma” de una imagen digital. Además, se estableció una ecuación para poder medir el grado de similitud entre “Firmas” de imágenes tratadas con los distintos tipos de transformación y la similitud de “Firmas” entre imágenes distintas. También se hicieron pruebas con 30 imágenes distintas y para cada imagen se obtuvieron 42 variantes con distintos porcentajes de rotación, escalamiento y ruido aditivo e impulsivo.

Por lo expresado anteriormente, se determinó que el paradigma SCM derivado de la PCNN tiene un mejor comportamiento para generar “Firmas” o huellas de las imágenes digitales. Pero sin la ayuda de alguna técnica extra o modificación del algoritmo pulsante dista en generar una buena “Firma”.

Abstract

This paper presents a method for obtaining global descriptors (features) of a digital image which serve as a "Signature" or trace of a digital image. The "Signatures" were obtained with three pulsating paradigms, and their behavior was analyzed with transformation processes such as rotation, scaling, impulse noise and additive noise. The purpose is to distinguish if the "Signatures" obtained are invariant to the transformation processes as well as to determine if the "Signatures" are invariant between different images.

In this research the paradigm PCNN (*Pulse Couple Neuronal Network*) for extracting features of digital images was selected, as well as its two variants ICM (*Intersection Cortical Model*) and SCM (*Spiking Cortical Model*). We experimented with descriptions or "Signatures" of a digital image obtained from the successive application of a pulse coupled neural network, in order to obtain a series of derivative images. By counting the number of bits of the pulsating binary images, we can obtain a time series which is hypothesized to describe the image.

Tests conducted in this thesis were implemented from nine different ways for obtaining a "signature" of a digital image. Furthermore it was established one equation to measure the degree of similarity between "Signatures" of images processed with various processes of transformation and the similarity of "signatures" between different images. We tested with 30 different images and each image has 42 variants that were obtained with different percentages of rotation, scaling, and additive and impulsive noise.

Due to the aforementioned, it was found that SCM paradigm derived from the PCNN has a better behavior to generate "Signatures" or traces of digital images. The PCNN is far from generating a good "Signature" without the help of any additional technique or the modification of the own algorithm.

Índice

Resumen.....	VII
Abstract.....	VIII
Índice.....	IX
Índice de figuras.....	XII
Índice de tablas.....	XV
Nomenclatura.....	XVI
Capítulo I.....	1
1.1 Motivación.....	1
1.2 Descripción del problema.....	2
1.3 Complejidad del problema.....	3
1.4 Objetivo general.....	3
1.4.1 Objetivos específicos.....	3
1.4.2 Alcances y limitaciones del proyecto.....	4
1.5 Justificación y beneficios.....	4
1.6 Organización de la tesis.....	5
Capítulo II.....	6
2.1 Antecedentes.....	6
2.2.1 Trabajos en CENIDET relacionados con Redes Neuronales Artificiales.....	7
2.2.2 Trabajos en CENIDET relacionados con Visión Artificial.....	8
2.2.3 Trabajos relacionados con Variantes del modelo RNP.....	9
2.2.4 Trabajos relacionados con RNPs y extracción de características.....	14
2.3 Análisis del problema.....	17
2.3.1 Problemas relacionados con las imágenes de texturas naturales.....	17
2.4 Propuesta solución.....	18
2.5 Discusión.....	18
Capítulo III.....	20
3.1 Elementos de las Redes Neuronales Artificiales (RNAs).....	20
3.1.1 La neurona biológica.....	20

3.1.2 Redes Neuronales Artificiales	22
3.2 Visión Artificial (VA)	26
3.3 Paradigma Red Neuronal Pulsante (RNP)	28
3.4 Modelo Matemático de las RNPs.....	31
3.4.1 <i>Pulse Coupled Neuronal Network</i>	31
3.4.2 <i>Intersecting Cortical Model (ICM)</i>	34
3.4.3 <i>Spiking Cortical Model (SCM)</i>	35
3.5 Extracción de características	36
3.6 Extracción de características con una RNP.....	37
3.6.1 Series de tiempo.....	37
3.6.2 Series con entropía.....	38
3.7 Mediciones	39
3.8 Discusión.....	42
Capítulo IV.....	43
4.1 Análisis y Diseño	43
4.1.1 Obtención de una “Firma” de una Imagen	48
4.1.2 Similitud entre imágenes	50
4.2 Implementación de los modelos pulsantes.....	51
4.2.1 Modelo Computacional <i>PCNN</i>	53
4.2.2 Modelo Computacional <i>ICM</i>	54
4.2.3 Modelo Computacional <i>SCM</i>	55
4.3 Implementación de las nueve “Firmas”	56
4.4 Implementación de la similitud de las “Firmas”	58
4.5 Discusión.....	59
Capítulo V.....	60
5.1 Experimentación.....	60
5.1.1 Tecnologías empleadas:.....	61
5.1.2 Base de datos de imágenes	61
5.1.3 Plan de pruebas	63
5.2 Resultados	64
5.2.1 Casos Rotación	64

5.3.2 Casos Escalado	71
5.3.3 Casos Ruido	75
5.3.4 Comparaciones entre imágenes	78
5.3.5 Otras técnicas básicas de extracción de características	83
5.4 Parámetros	86
5.5 Evolución de las “Firmas” o series de tiempo.....	87
5.6 Comportamiento de la “Firma”	90
5.7 Discusión.....	93
5.7 Conclusiones	94
Capítulo VI.....	99
6.1 Objetivos Logrados	99
6.2 Alcances logrados	100
6.3 Aportaciones.....	101
6.4 Conclusiones Generales	102
6.4.1 Conclusiones principales	102
6.4.2 Conclusiones personales.....	103
6.5 Trabajos Futuros.....	104
Bibliografía	106

Índice de figuras

Figura 2.1 Modelo simplificado de una PCNN	11
Figura 2.2 Modelo neuronal de 2 compartimentos a) modelo de compartimiento b) circuito equivalente.....	14
Figura 2.3 Tipos de procesamiento realizado por las RNA. RNA y sus variantes encontradas...	16
Figura 3.1 Neurona biológica y sus partes principales.	21
Figura 3.2 Modelo simplificado de la Neurona.	22
Figura 3.3 Problema separable linealmente y problema no separable linealmente	23
Figura 3.4 Diagrama del Multi-Layer Perceptron.....	23
Figura 3.5 Salida (Híper-plano) del MLP para XOR.....	24
Figura 3.6 Vista simplificada del proceso de conexión de la vista con el cerebro	27
Figura 3.7 El proceso de la Visión Artificial	28
Figura 3.8 Modelo del campo de Vinculación.....	29
Figura 3.9 Modelo de conexión de una sola neurona PCNN.....	29
Figura 3.10 Origen y variantes de las RNPs	30
Figura 3.11 Modelo Linking.	31
Figura 3.12 a) Representación esquematizada de la Actividad Interna sin estímulos inducidos. b). Representación esquematizada del Umbral dinámico mientras no ocurren pulsos.	32
Figura 3.13 Representación esquematizada de la salida de una RNP sin estímulos inducidos ...	33
Figura 3.14 Salida de una neurona pulsante	33
Figura 3.15 Ejemplo de las imágenes binarias de la salida de una RNP	37
Figura 4.1 Análisis de problema	44
Figura 4.2 Diagrama general para la obtención de firmas	44
Figura 4.3 Ejemplo de tres tipos de imágenes	45
Figura 4.4 Ejemplo del pre-procesamiento de las imágenes originales de entrada	45
Figura 4.5 Ejemplo del pre-procesamiento de las imágenes de entrada en escala a grises	45
Figura 4.6 Ejemplo de imágenes de entrada a la Red Neuronal Pulsante, finalmente es la imagen de entrada.....	46
Figura 4.7 Ejemplo de entrada a los Paradigmas pulso acoplados	46
Figura 4.8 Ejemplo de la salida de las RNPs como imágenes binarias	46
Figura 4.9 Ejemplo del conteo de pixeles encendidos en cada imagen binaria.....	46
Figura 4.10 Ejemplo de la aplicación de la Entropía para los valores numéricos de los pixeles encendidos.....	47
Figura 4.11 Ejemplo de la obtención de una “Firma” en base a la fórmula de Entropía.....	47
Figura 4.12 Ejemplo de una “Firma” guardada como un vector en formato .XML	47
Figura 4.13 Ejemplo de 9 “Firmas” distintas para la imagen de Montaña1	49
Figura 4.14 Ejemplo de imágenes binarias creadas por una RNP	48
Figura 4.15 Salida de imágenes binarias de una RNP	50

Figura 4.16 Ejemplo de una firma de una imagen	50
Figura 4.17 Diagrama de las Imágenes invariantes de comparación de "firmas" medición del grado de similitud.....	52
Figura 4.18 Modelo simple de una RNP.....	52
Figura 4.19 Modelo de una red neuronal pulsante PCNN	53
Figura 4.20 Modelo de una red neuronal pulsante ICM	54
Figura 4.21 Modelo de una red neuronal pulsante SCM	55
Figura 4.22 Ejemplo de la obtención de los nueve vectores que representan una "Firma" de una imagen	57
Figura 4.23 Diagrama de flujo de la función Unos()	58
Figura 5.1 Imágenes de distintos tipos de montañas. (Tipo 1)	61
Figura 5.2 Imágenes de distintos tipos de flores (Tipo 2).....	62
Figura 5.3 Imágenes de distintos tipos de pasto (Tipo 3)	62
Figura 5.4 Ejemplo de firmas obtenidas con SCM para los casos de montaña	63
Figura 5.5 Imagen rotada para estandarizar el tamaño de la imagen.....	64
Figura 5.6 Ejemplo de rotación de una imagen.	65
Figura 5.7 Graficas ejemplo para el caso de rotación sacadas de las "Firmas" de Motana1 con PCNN, ICM y SCM	65
Figura 5.8 Ejemplo de la obtención de las tablas promedio para cada imagen.	67
Figura 5.9 Resumen de los tres paradigmas con 9 series de tiempo o "Firmas"	70
Figura 5.10 Ejemplo de escalado para Montaña 1	71
Figura 5.11 Resumen de similitud de los tres tipos de imagen en escalado	74
Figura 5.12 Ejemplo de Ruido Aditivo y Ruido Impulsivo.....	75
Figura 5.13 Ejemplo de la Serie de tiempo $G[n]$, para montaña1 con ruido Aditivo(gaussiano) y Ruido Impulsivo ($S&P$)	76
Figura 5.14 Resumen de los tres tipo de imagen con ruido aditivo con SCM.....	77
Figura 5.15 Resumen de los tres tipo de imagen con ruido impulsivo con SCM.....	79
Figura 5.16 Graficas de comparación entre imágenes de distinto tipo con RNPs para tipo Montaña1 vs Montañas y Flores.....	80
Figura 5.17 Comparación de "Firmas" entre imágenes del mismo y distinto tipo con PCNN, ICM y SCM.....	81
Figura 5.18 Comparación de "Firmas" de distintos tipos de imágenes con PCNN, ICM, SCM..	82
Figura 5.19 Grafica de similitud para los tres tipos de imágenes, con las 9 series de tiempo	83
Figura 5.20 Evolución de una "Firma" para rotación con SCM.....	88
Figura 5.21 Evolución de una "Firma" para escalado con SCM.....	88
Figura 5.22 Evolución de una "Firma" para ruido impulsivo con SCM.....	89
Figura 5.23 Evolución de una "Firma" para ruido aditivo con SCM.....	89
Figura 5.24 Comportamiento de la Serie de tiempo $G[n]$, para figuras con escalado PCNN, ICM , SCM	90

Figura 5.25 Comportamiento de la Serie Energía de tiempo, para figuras con escalado PCNN, ICM, SCM.....	90
Figura 5.26 Comportamiento de la Serie Media residual, para figuras con escalado PCNN, ICM, SCM	91
Figura 5.27 Comportamiento de la Serie Desviación estándar, para figuras con escalado PCNN, ICM, SCM	91
Figura 5.28 Comportamiento de la Serie Entropía, para figuras con escalado PCNN, ICM, SCM	91
Figura 5.29 Comportamiento de la Serie Energía Logarítmica, para figuras con escalado PCNN, ICM, SCM	91
Figura 5.30 Comportamiento de la Serie Logarítmica, para figuras con escalado PCNN, ICM, SCM	91
Figura 5.31 Comportamiento de la Serie Energía entrópica, para figuras con escalado PCNN, ICM, SCM	91
Figura 5.32 Comportamiento de la Serie Ponderada, para figuras con escalado PCNN, ICM, SCM	92
Figura 5.33 Comportamiento de la Serie de tiempo $G[n]$, para figuras con rotación PCNN, ICM, SCM	92
Figura 5.34 Comportamiento de la Serie Energía de Tiempo para figuras con rotación PCNN, ICM, SCM	92
Figura 5.35 Comportamiento de la Media Residual, para figuras con rotación PCNN, ICM, SCM	92
Figura 5.36 Comportamiento de la Desviación Estándar, para figuras con rotación PCNN, ICM, SCM	92
Figura 5.37 Comportamiento de la Entropía, para figuras con rotación PCNN, ICM, SCM	92
Figura 5.40 Comportamiento de la Energía Logarítmica, para figuras con rotación PCNN, ICM, SCM	93
Figura 5.41 Comportamiento de la Serie Logarítmica, para figuras con rotación PCNN, ICM, SCM	93
Figura 5.42 Comportamiento de la Serie Entropía, para figuras con rotación PCNN, ICM, SCM	93
Figura 5.43 Comportamiento de la Serie Desviación Estándar, para figuras con rotación PCNN, ICM, SCM	93

Índice de tablas

Tabla 2.1 Trabajos relacionados con RNPs	14
Tabla 2.2 Tipos de procesamiento realizado por las RNA. RNA y sus variantes encontradas	17
Tabla 2.3 Problemas con imágenes de prueba	18
Tabla 4.1 Ejemplo para obtener la similitud entre “Firmas” o series de tiempo	51
Tabla 4.2 Comparación de similitud entre imágenes.....	58
Tabla 5.1 Ejemplo de una tabla de similitud entre todas las imágenes trasformadas de Pasto1 para PCNN.....	66
Tabla 5.2 Ejemplo de comparación de similitud entre rotación Series PCNN (Montaña 1)	67
Tabla 5.3 Ejemplo rotación Series ICM (Montaña 1).....	68
Tabla 5.4 Ejemplo rotación con Series SCM.....	69
Tabla 5.5 Resumen Series SCM tipo 1. Montaña.....	69
Tabla 5.6. Comparación con S, para imágenes con escalado PCNN.....	71
Tabla 5.7 Comparación con S para imágenes con escalado ICM.....	72
Tabla 5.8 Comparación con S, para imágenes con escalado SCM.....	72
Tabla 5.9 Resumen SCM, Tipo Montaña	73
Tabla 5.10 Evaluación con S para el caso ruido Aditivo con SCM para Montaña1.....	76
Tabla 5.11 Tabla resumen para un tipo de imagen (Montaña)	77
Tabla 5.12 Comparación PCNN Montaña y Flor	80
Tabla 5.13 Comparación ICM Montaña vs Flor.....	80
Tabla 5.14 Comparación SCM Montaña vs Flor	80
Tabla 5.15 Ejemplo de características para cinco imágenes.....	84
Tabla 5.16 Resumen de la comparación de similitud con S, con los diferentes paradigmas pulsantes	85
Tabla 5.17 Comparación de la serie entropía vs energía ponderada.....	86
Tabla 5.18 Parámetros utilizado para PCNN	86
Tabla 5.19 Parámetros utilizado para ICM	87
Tabla 5.20 Parámetros utilizado para SCM	87
Tabla 6.1 Objetivos propuestos contra objetivos logrados	97
Tabla 6.2 Tabla de alcances propuestos y alcances logrados.	98

Nomenclatura

F_{ij} , Feeding

U_{ij} , Actividad Interna

L_{ij} , Linking

E_{ij} , Umbral Dinámico

Y_{ij} , salida de RNP (0 - 1)

$\alpha_F, \alpha_L, \alpha_E$; constantes para el tiempo de decaimiento

V_F ; magnitud de ajuste del del *feedback*

V_L ; magnitud de ajuste del *Linking*

V_E ; magnitud de ajuste del Umbral dinámico

β ; Coeficiente de conexión de las actividades internas,

M_{ijkl}, W_{ijkl} ; Matrices de convolución (Mascaras entrada 3 x 3)

S_{ij} , Imagen de entrada

f, g , constantes de decaimiento

h , magnitud de escalamiento para Y

U_{ij} , Entrada *Feedback* (*Input- Solo Caso SCM*)

Y es la imagen de salida de una RNP

índices (i,j) representan una posición ya sea de la neurona o la imagen

índices (k,l) representan una posición ya sea de la neurona o la imagen (vecinos de i,j)

n , numero de iteración de la RNP

μ , representa la media de la serie de tiempo

v , es una variable de tamaño n (número de iteraciones de la RNP) que toma el valor de n y descendiente a 0.

P_1 , es la probabilidad de que existan 1's en la imagen binaria

P_0 , es la probabilidad de que existan 0's en la imagen binaria

$G[n]$, Serie de tiempo para Y

$H[p]$, Entropía de Y

x es la tupla de 2 filas para el cálculo de la distancia entre sus filas

m es la dimensión de la tupla

k es el índice de los elementos de la tupla

max es la función de encontrar al máximo de las tuplas

T es la transpuesta de la tupla de características x

C^{-1} es la inversa de la covarianza de las dos tuplas

m' es la media de los valores de la tupla de características respetivas

$g_p[n]$, representa la secuencia de la entropía estándar (es la salida de la serie de tiempo), de la imagen p

$g_q[n]$, representa la secuencia de la entropía estándar (es la salida de la serie de tiempo), de la imagen q .

Capítulo I

Introducción

Esta sección describe a detalle la problemática que se requiere resolver y plantea las metodologías implementadas para extraer características de una imagen digital con la ayuda de una RNP, se describe el objetivo general, que se subdivide en varios objetivos específicos. Así mismo se describen los alcances, limitaciones, metodología y organización del documento de tesis.

Las imágenes son procesadas por las redes neuronales pulsantes dando lugar a una secuencia de imágenes binarias, estas imágenes contienen información de la imagen original pero no puede ser utilizadas por contener demasiada información, por lo se utilizó una transformación de la información de las imágenes pulsantes resultantes (características o descripciones), representándola por medio de una serie de tiempo o “Firma” de la imagen, que es la consecuencia de la sumatoria de los unos de las imágenes binarias pulsantes, cuyo comportamiento se muestra en esta tesis.

1.1 Motivación

La capacidad del cerebro humano para pensar, recordar y resolver problemas es la inspiración de muchos científicos para intentar modelar a través de la computadora el funcionamiento del cerebro humano [McCulloch, 1943].

El cerebro humano tiene varias características deseables para el funcionamiento de un sistema de cómputo, como la tolerancia a fallas, la capacidad de generalizar y la velocidad con la que detecta anomalías en el ambiente, entre otras. En décadas pasadas, surgieron modelos de Redes Neuronales Artificiales (RNAs) con diversas teorías sobre el funcionamiento de las Redes Neuronales Biológicas. Un área en que se utilizan ampliamente dichas redes es el procesamiento de imágenes. Al respecto existe gran cantidad de trabajos propuestos con RNAs, [Zhang, 2010], [Chacon, 2011], [Ramírez, 2012], [Ebied, 2013], [Majid, 2014]. Lo anterior ha motivado a revisar acerca de la contribución de dichos trabajos en estudios anteriores.

Más recientemente ha surgido una nueva generación de RNAs cuya característica principal es su naturaleza “pulsante”, similar a lo que ocurre en el cerebro biológico.

En este trabajo se desea evaluar de primera mano qué tan bien opera este tipo de RNAs para el caso de extracción de descripciones de imágenes digitales.

Finalmente las RNPs (Tercera Generación) llaman la atención por su novedosa interpretación del funcionamiento de una neurona biológica especialmente de la corteza visual del gato, las RNPs generan un tren de pulsos, más cercanamente a cómo lo hace una neurona biológica.

1.2 Descripción del problema

Las Redes Neuronales Artificiales se han empleado en muy diversos dominios, destacando el área de Visión Artificial. Aunque se han obtenido buenos resultados, en general existen aún problemas con la extracción de características de una imagen, pero usando las series de tiempo de las Redes Neuronales Pulsantes (RNPs) para la obtención de características de una imagen se espera obtener buenos resultados, según la literatura. Las Redes Neuronales tipo Pulsantes son una variante que extrae datos de una manera distinta a los anteriores paradigmas neuronales y ya han sido aplicados en esta área de procesamiento de imágenes digitales [Lindblad, 2005] y [Ramírez, 2012].

El presente trabajo de tesis servirá para experimentar y hacer una evaluación adicional del uso y aplicación del paradigma pulsante para problemas donde la necesidad de extraer características sobre las imágenes es importante.

1.3 Complejidad del problema

Cuando se requiere de la extracción de características de una imagen es importante que la representación sea única, es decir que sea invariante a la rotación, escala y ruido. Las imágenes binarias contienen abundante información y puede ser extraída como una característica de una imagen pero los datos pueden ser excesivos. Por lo tanto algunas transformaciones de las imágenes binarias podrían representar a la imagen original. Aunque existen bastantes trabajos relacionados con este tema, este problema sigue siendo complejo de resolver para ciertas imágenes.

Adicionalmente se considera que el modelo de RNP es más sofisticado por tener un comportamiento más cercano al modelo biológico que los modelos anteriores, porque toma en cuenta nuevos descubrimientos sobre el funcionamiento del cerebro, en general de la corteza visual, de ahí la complejidad del problema. Otro factor importante es que la obtención automática de características de una imagen digital sea guardada en una “Firma” o huella, y para la recuperación no sea necesaria toda una base de imágenes digitales.

1.4 Objetivo general

Analizar, implementar, experimentar y evaluar la RNAs tipo Pulsante, dentro del dominio de Visión Artificial para problemas de reconocimiento de patrones a través de la extracción de características o extracción de descripciones¹ de una imagen.

1.4.1 Objetivos específicos

Los objetivos específicos de este proyecto se presentan a continuación:

- 1) Desarrollar e implementar computacionalmente un paradigma neuronal pulsante.
- 2) Definir casos de prueba para las áreas de pre-procesamiento de imágenes y extracción de características dentro de la Visión Artificial para reconocimiento de patrones y realizar la experimentación correspondiente.
- 3) Identificar y aplicar un mecanismo de evaluación para las redes neuronales tipo Pulsante.
- 4) Detectar las ventajas y desventajas de las RNP para extraer características de una imagen.

¹ En este trabajo los términos “extracción de descripciones” y “extracción de características” se emplean indistintamente.

1.4.2 Alcances y limitaciones del proyecto

Alcances:

- Estudiar el área de RNAs tradicional.
- Revisar los problemas típicos de las RNAs en el dominio de Visión Artificial para el área de extracción de características.
- Estudiar e implementar la RNP y una variante llamada SCM (por sus siglas en inglés *Spiking Cortical Model*) importante para problemas de reconocimiento de patrones a través de la extracción de características.
- Experimentar con bases de datos de imágenes digitales conocidas en CENIDET para la extracción de características.
- Realizar un estudio comparativo con técnicas o algoritmos tradicionales pulsantes que extraigan características de una imagen. El tiempo de procesamiento no será relevante.
- Comparar las RNP contra técnicas tradicionales de extracción de características.

Limitaciones:

- De ser posible se utilizarán mecanismos y medidas existentes en la literatura.
- De ser posible no se propondrá un nuevo mecanismo o medida para evaluar los resultados.
- El número de imágenes a procesar estará limitado a las capacidades de velocidad y almacenamiento de una PC típica.
- Las comparaciones se harán contra resultados presentados en la literatura o utilizando *software* y herramientas ya desarrolladas (por ejemplo, OpenCV).
- No se busca mejorar los resultados sino más bien detectar con claridad las ventajas y desventajas de la RNP para la extracción de características de una imagen.

1.5 Justificación y beneficios

En el CENIDET aún no se ha generado investigación respecto a Redes Neuronales Pulsantes para extraer características de una imagen. Por esta razón en el presente trabajo se pretende crear una nueva perspectiva que aporte a la solución de algunos de los problemas en este campo, tales como la calidad o la complejidad de paradigma para extraer características de una imagen.

En el presente proyecto se propone implementar y evaluar Redes Neuronales tipo Pulsante, para el reconocimiento de patrones a través de la extracción de características por medio de la firma o huella de la imagen. De los resultados se obtendrá datos para comparar las distintas diferencias que poseen las técnicas descritas en este trabajo de investigación en extracción de características. Estas evaluaciones permitirán aumentar la certeza para determinar qué técnica resulta más apropiada o recomendable para la extracción de características de una imagen.

1.6 Organización de la tesis

Este documento está estructurado de la siguiente manera. En el capítulo 2 se incluyen trabajos relacionados con las RNPs; estos trabajos son tomados principalmente de capítulos de libros, revistas y artículos.

El capítulo 3 contiene la descripción detallada de las áreas involucradas para realizar la experimentación correspondiente de las RNPs. Primero se aborda el tema de Visión Artificial que incluye la visión humana y cómo se compone la vista (especialmente la corteza visual); después se describirá una neurona biológica y su funcionamiento así como el funcionamiento de una neurona artificial; extracción de características, medidas de similitud; por último se explicará el funcionamiento de una neurona artificial pulsante, que es la parte central de la investigación.

El capítulo 4 explica el motivo de la selección de las modificaciones al modelo principal de una red neuronal artificial pulsante y el proceso de selección de firmas.

El capítulo 5 muestra un conjunto de experimentos relacionados con RNPs, que se seleccionaron utilizando una base de datos de 30 imágenes.

El capítulo 6 de este trabajo de investigación, resume lo alcanzado en este trabajo.

Al final de todos los capítulos se proporciona toda la Bibliografía citada en el presente documento de tesis.

Capítulo II

Estado del Arte

En este capítulo se presentan los enfoques y herramientas actuales en el dominio de la Red Neuronal Pulsante (RNP) o *PCNN* por sus siglas en inglés (*Pulse-Coupled Neuronal Network*) y variantes, que fueron encontrados en diversas publicaciones, creando así una idea general de la concepción actual de las Redes Pulsantes en el dominio de extracción de características de imágenes digitales. Las propuestas son clasificadas de acuerdo a:

- a) Dominio de la Red Neuronal Pulsante en el área de extracción de características de imágenes digitales.
- b) Variantes del modelo RNP.

A continuación se resumen los trabajos recopilados que han sido analizados en el CENIDET y el extranjero con RNPs. Con base en la información recopilada se desarrolla un análisis del problema y se diseña una propuesta de solución.

2.1 Antecedentes

En este apartado se describen algunas investigaciones realizadas en CENIDET y el extranjero relacionadas al tema citado en esta tesis, relatan las circunstancias para comprender la evolución de las RNPs y determinar la interpretación correctamente de las RNA (Primera y segunda generación) en función de algunas de las aplicaciones dadas a continuación.

2.2.1 Trabajos en CENIDET relacionados con Redes Neuronales Artificiales

Reconocimiento de patrones de fallas en generadores eléctricos empleando redes neuronales artificiales [Rocha, 1991]

Plantea el uso de RNAs para reconocer patrones de fallas en generadores eléctricos, evalúa el desempeño de los paradigmas: *Backpropagation*, PHAF II y *Radial Basis Function* (RBF), y en base a los resultados obtenidos determina que PHAF II, es la que mejor desempeño tiene entre las comparadas, por esa razón realiza su implementación en el Sistema Computacional prototipo denominado “Diagnóstico de fallas en generadores eléctricos con redes neuronales (DIFGREN)” el cual permite, diagnosticar fallas en generadores eléctricos de forma automática mediante la interpretación de registros gráficos obtenidos en tiempo real.

Implementación de una red neuronal holográfica para el control de un brazo robótico articulado [Hernández, 2003]

Se trabaja con una RNA holográfica para el control de un brazo robótico articulado la cual fue evaluada contra una RNA del tipo *Backpropagation* encontrando que la última sólo reconoce figuras en imágenes con máximo 20% de ruido y la primera logra hacerlo en imágenes con hasta 30% de ruido por lo que con base en esta superioridad la implementa en un simulador de control para dicho robot.

Metodología para el diseño de sistemas híbridos Neuro-Simbólicos aplicados a problemas de inspección visual [Cruz, 2010]

Presenta una metodología para desarrollar sistemas computacionales que simulan el comportamiento humano durante la toma de decisiones de control de calidad y reconocimiento de patrones, en la que a través de diversas etapas desarrolla estrategias para la integración de sistemas neuronales, simbólicos y numéricos. La red que implementa en su trabajo es el *Perceptron* ya que debido a sus características es la que mejor se integra a la metodología planteada.

Control embebido de un vehículo guiado automáticamente mediante redes neuronales artificiales [Martínez, 2012]

Aplica las RNAs en el control de un vehículo guiado automáticamente, específicamente implementa una red neuronal recurrente de alto orden (RHONN por sus siglas en inglés) en el control embebido de dicho vehículo y lo compara contra los resultados obtenidos previamente por [Camarena, 2009], encontrando que el control usando la red RHONN tiene un mejor desempeño.

2.2.2 Trabajos en CENIDET relacionados con Visión Artificial

Indexado y recuperación de imágenes por contenido [Troncoso, 2007]

Esta tesis consistió en realizar un sistema de indexado y recuperación automática de imágenes, es decir, realizar un sistema CBIR (*Content-Based Image Retrieval*). Para la búsqueda de las imágenes se implementaron dos criterios: por una descripción textual o dada una imagen o sub-imagen de referencia. Se utilizaron texturas con agua, con árboles, con montañas y flores, se definieron sub-categorías, para la categoría agua, tierra o arena, piedras y cielo; para la categoría árboles son: árbol, tierra o arena, pasto y cielo.

Caracterización automática de imágenes en un dominio transformado [Galeana, 2008]

Este trabajo de tesis permitió verificar que si transformando el dominio de la imagen, se puede obtener una mejor caracterización o descripción de su contenido, en comparación con los procesos tradicionales que se hacen a las imágenes en la etapa de segmentación. Este enfoque propuesto en esta tesis se basa en que se aplique a las regiones de interés ciertas transformaciones a los píxeles que permitan obtener descriptores independientes de las formas o colores de los objetos, en los casos en que los objetos que pertenecen a la misma clase no tienen un color o forma única.

Se trabajó con las siguientes categorías: paisajes con flores, paisajes con árboles, paisajes con montañas, piel y construcciones. Se implementaron transformadas en el dominio: *wavelets* (Haar, Daubechies 4, Daubechies 5 y Daubechies 8), de color (RGB normalizado, HSI, YQQ, YES, XYZ, CIE Luv, CIE Lab, CMY y YCbCr) y paramétrico (*Hough* para líneas), con sus respectivos descriptores.

Los resultados muestran que el dominio paramétrico y el de color, bajo este conjunto de descriptores, son mejores que el dominio original y que en el dominio *wavelets* se obtienen buenos resultados cuando se trabaja con variaciones de escala, traslación e iluminación.

Recuperación automatizada de imágenes mediante la implementación de descriptores del estándar MPEG-7 [Pérez, 2014]

Esta investigación fue desarrollada por [Pérez, 2014]. Realiza la recuperación de imágenes utilizando descriptores del estándar *Multimedia Content Description Interface* (MPEG-7), para lo cual se desarrolló un sistema denominado Recuperación de Imágenes por Ejemplo (RIPE) aplicando los descriptores MPEG-7 de color y textura denominados *Color Layout Descriptor* (CLD) y *Edge Histogram Descriptor* (EHD). Para la experimentación se utilizaron cuatro *datasets*, tres de éstos empleados en la literatura y uno elaborado por este autor. Se comparó el

rendimiento del sistema elaborado por [Troncoso, 2007] contra la implementación del sistema basada en MPEG-7 y se obtuvieron resultados parecidos al usar el descriptor CLD. Para medir los resultados de recuperación de imágenes, se utilizó el *Average Normalized Modified Retrieval Rank (ANMRR)*. Con base en los resultados se propuso usar cinco medidas de distancia para mejorar la recuperación de imágenes empleando el descriptor de textura.

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

Dentro de este trabajo de tesis se propone incursionar en el tema de Redes Neuronales Pulso Acopladas, para detectar las ventajas y desventajas de este paradigma PCNN, al ser aplicadas.

Se realiza un estudio de las variantes de las RNPs para el proceso de detección de bordes y segmentación de imágenes y se comparan los resultados contra otras técnicas de detección de bordes tradicionales, al igual que los tiempos de procesamiento entre una metodología y otra. A futuro se busca hacer experimentos con imágenes médicas.

2.2.3 Trabajos relacionados con Variantes del modelo RNP

En esta categoría se presentan los trabajos que parten del modelo RNP, ya sea de manera simplificada o realizando una fusión con otra metodología, para el pre-procesamiento y extracción de características de imágenes.

Aplicaciones de la RNP [Jhonson, 1999]

Este trabajo describe las redes neuronales pulsantes y principalmente el campo de modulación, se demuestra que es una característica universal de cualquier modelo biológico de dendritas. Se revisan las aplicaciones e implementaciones de la RNP y describe en detalle el modelo RNP para la extraer características de una imagen.

Procesamiento de imágenes médicas con ICM [Kinser, 2004]

Kinser describe el mecanismo de funcionamiento de la variante *Intersecting Cortical Model (ICM)* la cual permite obtener imágenes de pulso largo a través de varias iteraciones en donde se pueden encontrar segmentos, bordes y texturas que pertenecen a la imagen de entrada, con lo que se puede crear un motor de reconocimiento de la textura del espectro de los píxeles individuales en donde a partir de regiones seleccionadas se desarrolla una biblioteca de reconocimiento. La precisión de este método depende de la representante de las firmas y su clasificación, por lo que dentro de las imágenes médicas se puede lograr que los parásitos puedan ser rápidamente reconocidos. Una de las ventajas notorias que mencionan en ésta metodología es que la *ICM*

está utilizando firmas para representar objetos y que a su vez puede extraer las características internas de los objetos y representarlos con estas firmas.

Adelgazamiento de imágenes binarias usando auto-ondas generadas por una PCNN [Shang, 2006]

Esta investigación se centra en las imágenes binarias, ya que una red neuronal pulsante genera auto-ondas de los objetos viajando en diferentes direcciones. Se hace un estudio a partir de los experimentos, donde muestran una eficiente extracción del esqueleto de las imágenes procesadas. Finalmente propone un nuevo algoritmo pulsante para mejorar los contornos del esqueleto y de menos costo.

Simplificación de la PCNN para la extracción de características mediante la matriz de tiempo [Liu, 2012]

Existen técnicas de extracción de características que tratan de hacer coincidir la mayoría de los puntos destacados de una imagen contra otra. La matriz de tiempo de una imagen es una matriz del mismo tamaño de la imagen y guarda en que tiempo fue disparada la neurona, es decir es un historial de cada neurona. De esta forma se guarda información espacial de la imagen, ya que los puntos destacados son disparados siempre en el mismo tiempo. Así mismo hacen una modificación a la PCNN, para que las neuronas sean disparadas en un mayor tiempo. El experimento muestra buenos resultados para las imágenes escaladas y con rotación.

PCNN simplificada para detectar defectos textiles por [Shi, 2007]

Esta investigación describe un método de segmentación de imagen basado en la simplificación de una RNP por Shi, para detectar defectos textiles, ya que detecta rasgos delicados de defectos complicados por las variaciones del tejido en las texturas y los cambios en los factores ambientales (por ejemplo, iluminación, ruido). A través de un nuevo parámetro describen la diferencia de contraste en la fila y la columna entre la imagen analizada y una imagen libre de defectos de la misma tela, el cual llaman desviación del contraste (*DOC*). A través de las evaluaciones que pudieron observar y los datos cuantitativos de las imágenes tomadas con una cámara de barrido lineal y las imágenes de la base de datos *TILDA* prueban que el método simplificado de RNP es eficaz y robusto para la segmentación de defectos.

Nuevo modelo cortical de pulsos para la recuperación de textura invariante y procesamiento de imágenes [Zhan, 2009]

Este artículo analiza y propone a partir de estudios relacionados con modelos neuronales pulsantes artificiales, el modelo cortical de pulsos (SCM).

Describe algunos métodos populares de extracción de texturas, además del modelo cortical de pulsos (SCM), seguido de una breve analogía entre filtros digitales recursivos de primer orden y las neuronas del cuerpo humano. Así mismo realiza una comparación entre Redes Neuronales Pulso Acopladas, el Modelo Cortical de Pulsos (SCM) y el Modelo de Intersección Cortical (ICM).

La aportación consiste en un esquema de recuperación de características invariantes que es eficaz en la extracción de la rotación y escala (según los resultados experimentales) y se presenta un nuevo modelo cortical junto con las ventajas que se obtienen al ser utilizado con otras aplicaciones de procesamiento de imágenes, lo cual es importante ya que mejora la supresión de ruido de las imágenes y se realiza una segmentación de imágenes y detección de bordes mejorando la clasificación de texturas invariantes y el sistema de recuperación de estas mismas.

Simplificación de la PCNN [Xiao, 2009]

Los modelos *PCNN* modificados requieren de un número de iteraciones (su realimentación) y el efecto del ruido en un cierto punto. Con el fin de reducir aún más la complejidad computacional y el efecto del ruido en las imágenes, Xiao propone un modelo simplificado basado en la Red *PCNN*, como se muestra en la Figura 2.1

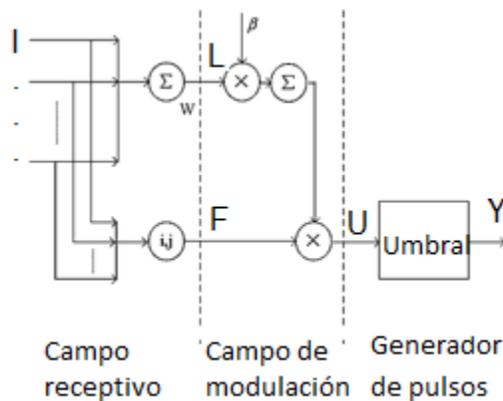


Figura 2.1 Modelo simplificado de una PCNN

El modelo propuesto elimina en primer lugar todos los integradores con fugas en el campo de alimentación y el campo de enlace, y los integradores con fugas idénticas, lo que reducirá las iteraciones. La entrada en el *linking* L_{ij} está sólo para recibir los estímulos externos L_{ij} , que no era una variable en el tiempo, pero una constante para una imagen de entrada. Esta simplificación fue la modificación fundamental del algoritmo *PCNN* estudiado. Asimismo, la función de paso fue eliminado, y el umbral U_{ij} fue una constante ajustada manualmente para controlar el disparo de toda la red. Los parámetros reservados en el modelo simplificado *PCNN* eran W_{ijkl} , β y Θ_{ij} .

En este estudio el modelo propuesto se utilizó para extraer el contorno de la imagen con poco ruido, por lo que en un trabajo futuro proponen evaluar la robustez de la red.

Imagen RS con Segmentación Automática PCNN y la entropía [Zhang, 2010]

En esta propuesta utiliza la entropía de información como herramientas para evaluar el efecto del tratamiento de la imagen, es decir, cuanto mayor es el valor de la entropía de información mejor será la imagen. Además proponen un algoritmo de segmentación de RNP basado en el principio de máxima entropía, el cual determina el número de ciclo con la entropía máxima con el fin de realizar la mejor segmentación de la imagen automáticamente en función de las regiones. A partir de sus experimentos determinan que el modelo de Red neuronal Pulsante es efectivo para la segmentación de imágenes.

Reducción de ruido usando un Algoritmo genético basado en una RNP [Zhang, 2011]

El artículo describe la falta de definición del borde. En consecuencia, en este trabajo presenta un método de adaptación de un algoritmo genético basado en el modelo de RNP, para descartar el ruido gaussiano blanco aditivo. A diferencia de los métodos basados RNP convencionales, GA-PCNN utiliza un filtro de difusión anisotrópica para reemplazar el filtro de mediana y optimiza los parámetros de una RNP simplificada mediante algoritmo genético adaptativo. Los resultados indican que GA-PCNN tiene un mejor rendimiento que las técnicas de eliminación de ruido anteriores, es decir, filtro mediana, los métodos basados en filtros de Wiener, filtra difusión anisotrópica y la RNP convencional.

Aplicaciones de una Red neuronal pulso acoplada (Extracción de características) [Ma, 2010]

El Capítulo 7 del libro *Applications of Pulse-Coupled Neural Networks*, describe detalladamente la salida de una RNP dada una imagen, muestra que aun distorsionando la imagen en rotación, escala y ruido la “firma” de la imagen es invariante. Muestra lo fuerte que pueden ser las RNP para extraer características de una imagen con el objetivo de reconocer el objeto y que la “Firma” sea una representación o característica única de la imagen original pero aunque la información de las imágenes binarias contienen mucho información de una imagen, también se muestra el uso de transformadas binarias o formas de representación de la “Firma” original.

Clasificador de Series de tiempo para segmentación de texturas PCNN-FCM [Chacon, 2011]

Esta propuesta se centra en la segmentación de texturas apoyándose de una RNA la cual permite obtener un mejor procesamiento de los datos. Debido a que la segmentación de imágenes no es una tarea fácil, se implementó el modelo RNP para investigar su potencial junto con el algoritmo *Fuzzy c-means (FCM)* y propone una segunda etapa de segmentación a través de operaciones morfológicas. El hallazgo más importante en el estudio de Chacon es que en el método de evaluación los experimentos de sensibilidad al brillo, sensibilidad con respecto a la textura y sensibilidad a la textura de adyacencia, indicó que la función de series de tiempo de la RNP logró capturar información excluida por otros modelos en las texturas primitivas.

Modelo Simple de PCNN (S-PCNN) [Wei, 2011]

En esta investigación [Wei, 2011] estudia un modelo simple de RNP (*S-PCNN*) y aplica la segmentación de imágenes, abordando el ajuste automático del umbral de decaimiento constante de tiempo y presentando un nuevo estándar de selección de salida de la RNP. En base a su análisis se determina que una buena segmentación por RNP ocupa de todos los parámetros expuestos durante el procesamiento y se describe 4 contribuciones principales:

Un nuevo método basado en el modelo simplificado de RNP que se propone para segmentar las imágenes automáticamente. Los ajustes de parámetros se estudiaron para asegurar que el umbral de decaimiento de *S-PCNN* se ajustara adaptativamente de acuerdo con las características generales de la imagen.

Basado en la serie de tiempo en *S-PCNN*, un simple criterio de selección de los resultados finales se presenta para promover la eficiencia del método propuesto.

Construcción y evaluación de una Red Neuronal tipo “Adaptive Bidirectional Associative Memory” [Morales, 2013]

Este trabajo de tesis evalúa las RNAs del tipo *Adaptive Bidirectional Associative Memory* (ABAM) para medir su capacidad de filtrar ruido a través de la aplicación “*ABAM Evaluator*”, la cual permite entrenar la RNA, probar la recuperación de imágenes y medir el tiempo requerido para realizar dicha recuperación.

La RNA de tipo ABAM implementada procesa imágenes en blanco/negro; las imágenes en escala de grises y de color real son procesadas por una variante de BAM. Además presenta una mejora al algoritmo original de las ABAM con el fin de habilitarla para trabajar con imágenes afectadas por ruido, obteniéndose un muy buen filtrado de ruido.

Otros trabajos relacionados

La Tabla 2.1 muestra un resumen de otros trabajos relacionados con distintas RNPs, lo que indica popularidad del modelo neuronal pulsante.

Tabla 2.1 Trabajos relacionados con RNPs

Artículo	Técnica	Datos	Resultados	Observaciones
[Haiyan, 2008]	Algoritmo basado en PCNN	Imágenes SAR en escala gris	El nuevo algoritmo requiere solo de una iteración	Segmentación de imágenes SAR
[Wang, 2010]	Algoritmo basado en multi-PCNN	Imágenes de texturas en escala de grises	Multi PCNN con Gabor Wavelet	Segmentación de imágenes con filtros Gabor y multi-PCNN
[Ma, 2010]	Algoritmo basado en PCNN	Imágenes en escala de grises con ruido Aditivo	Comparación entre dos métodos propuestos con PCNN vs filtro mediana y wiener	Reducción de ruido Aditivo
[Shuiming, 2010]	Algoritmo basado en PCNN	Imágenes en escala de grises, con ruido Aditivo e Impulsivo	Muestran las diferencias entre “Firmas” con la distancia euclidea	Reconocimiento de imágenes con ruido Impulsivo y Aditivo
[Francis, 2012]	Neuronas acopladas	Análisis teórico	Formalismo teórico del acoplamiento de dos neuronas	Investigaciones empíricas de la sincronización entre dos neuronas, basado en los ‘histogramas de correlación cruzada’

2.2.4 Trabajos relacionados con Redes Neuronales Pulsantes y extracción de características

El dominio de las Redes Neuronales Pulsantes ha sobresalido en la última década dentro del entorno de extracción de características de imágenes digitales. En esta sección se concentran los trabajos que hacen uso del paradigma pulsante para el procesamiento de imágenes, en donde cada uno de los trabajos colaboro con la interpretación y el funcionamiento para la aplicación de una RNP.

Modelos RNP (Red neuronal pulsante) [Johnson, 1999]

En la investigación de [Johnson, 1999] describe el modelo de RNP, en donde el término “modulación de campo de enlace” (*linking*) se muestra como una característica universal observable en cualquier modelo basado en una red neuronal con dendritas, o interconexiones neuronales. Además de las diversas aplicaciones de las Redes Pulso Acopladas, se hace un estudio de la dinámica electroquímica de las neuronas y se menciona que la mayoría de los trabajos relacionados con los modelos biológicos se han preocupado principalmente por los

algoritmos adaptativos para clasificadores de datos, como en el caso del procesamiento de imágenes.

Se realizan dos comparaciones entre un modelo de celdas y un circuito equivalente, en donde el primero muestra el cuerpo de la célula con el comportamiento de las dendritas (ver Figura 2.2)

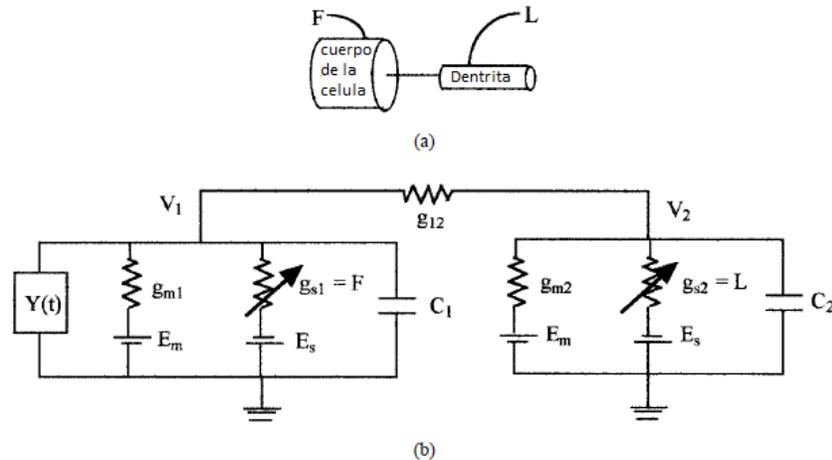


Figura 2.2 Modelo neuronal de 2 compartimentos a) modelo de compartimiento b) circuito equivalente

Redes neuronales artificiales para el procesamiento de imágenes, una revisión de la última década [Ramírez, 2011]

Este trabajo analiza el amplio uso de las Redes Neuronales en el campo del procesamiento de imágenes, en una revisión de 200 artículos donde se documentan algoritmos que utilizan alguna arquitectura de Redes Neuronales Artificiales para tareas de clasificación, reconocimiento o segmentación en imágenes digitales. Además esta revisión presenta los distintos modelos de redes así como sus modificaciones y aplicaciones (ver Figura 2.3). Así mismo se documentan algunos aspectos de nuevas redes neuronales incluyendo los modelos pulsantes. De acuerdo al análisis de este estudio, la segmentación fue la aplicación más común de varias arquitecturas de RNA, ya que es difícil extraer con métodos clásicos de procesamiento formas irregulares que no tienen un patrón tan repetible.

Proc./Red	ART	CNN	MLP, BP	O NN	RNN	PRNN	RBF NN	SOM	OTRAS	TOTAL
NR	0	0	0	0	1	0	0	0	0	1
TS	0	2	0	1	1	4	0	1	1	10
VS	1	2	0	0	0	0	0	3	2	8
CS	0	8	0	0	1	1	1	1	1	13
SS	2	6	10	9	4	5	7	5	5	53
Ct	9	0	0	0	2	0	1	2	1	15
Cr S	2	1	1	0	0	0	1	7	1	13
CL	15	0	5	2	3	5	10	1	2	43
VR	1	0	0	0	2	0	0	0	0	3
OTROS		2	1	0	1	0	0	2	2	8
TOTAL	30	21	17	12	15	15	20	22	15	167

ART	CNN	ONN	PCNN	RNN	PRNN	RBF NN	SOM	OTRAS	MLP, BP
ART MMAP	DCNN	LEGION	ICM	Elman Jordan	PNN	Autoadaptiva	SOFM	Caóticas	
MARTMAP	SON		PCNN multicanal	Lotka Volterra RNN	WPNN	FCM RBFNN	PSOM	Neurodifusas	MLP GMP
SFAM	TCNN		Encadenamiento unitario	DCRNN	GMM	NeuroRBFNN	FCNN	TCAN	MLP pesos gaussianos
	PoCNN			RNNBP	RNA aleatoria		SOTFN	TDNN	
	CTCNN			IO RNN			SASOM	FNN	
				LSTM RNN			SOBS	Membrana excitable	
				Hopfield			SOTM		

Figura 2.3 Tipos de procesamiento realizado por las RNA. RNA y sus variantes encontradas

Tres Aplicaciones para el procesamiento de imágenes con RNP [Chacon, 2007]

Este trabajo presenta tres aplicaciones para el procesamiento de imágenes de la Red Neuronal Pulsante.

La primera aplicación o esquema como le es llamado en este estudio es llevado a cabo con el fin de obtener una visión del comportamiento del paradigma RNP a través de la segmentación.

La segunda está relacionada con la localización automática de objetivos (*ATL*).

Y la tercera con el reconocimiento de rostros a través de la extracción de características.

Los resultados que se obtienen a partir de estas tres aplicaciones permiten sugerir que la RNP puede considerarse como un buen elemento pre-procesador para los sistemas de visión, proporcionando un mejor rendimiento ya que se demostró a través de los experimentos realizados el potencial de la Red para generar información útil sobre todo en tareas de segmentación y extracción de características.

Además muestra las aplicaciones en sistemas híbridos electro-ópticos los cuales fueron la primera implementación de una RNP y en donde estas abstracciones pueden centrarse en la utilidad práctica y la aplicación eventual de *hardware* automatizado de las RNPs.

2.3 Análisis del problema

A continuación se presentan los problemas relacionados con la presente tesis y se describe de forma general la solución propuesta para realizar una descripción de imágenes naturales invariante a cambios de escala, rotación y ruido.

2.3.1 Problemas relacionados con las imágenes de texturas naturales

Para seleccionar las categorías de las texturas naturales con las que se trabajó, se revisó el estado del arte y se analizó cuáles son las texturas naturales utilizadas con más frecuencia. En la Tabla 2.2 se detalla información del artículo o tesis, las clases de texturas utilizadas y el número de imágenes que se emplean.

Con base en la información presentada en la Tabla 2.2 se seleccionaron los tipos imágenes naturales que se utilizarán en esta investigación, las cuales son: flores, césped y montañas. En la Tabla 2.3 se presenta un resumen de las categorías de imágenes de texturas que se usan en esta tesis. También se describen algunos problemas que se presentan al utilizar estas categorías.

Tabla 2.2 Tabla de bases de imágenes del CENIDET

Autor	Tesis	Clase	No. Imágenes
[Pérez, 2015]	Métricas y funciones de semejanza para texturas. Tesis de Maestría en Ciencias Computacionales	<ul style="list-style-type: none"> • Flores • Montaña • Pasto 	
[Avellaneda, 2009]	Caracterización de texturas naturales. Tesis de Maestría en Ciencias Computacionales	<ul style="list-style-type: none"> • Árboles • Arena • Cielo • Montaña • Nubes 	243 163 194 142 200
[Galeana, 2008]	Caracterización Automática de Imágenes en un Dominio Transformado. Tesis de Maestría en Ciencias Computacionales	<ul style="list-style-type: none"> • Flores • Cielo • Árboles • Montañas 	100 100 100 100
[Troncoso, 2007]	Indexado y Recuperación de Imágenes por Contenido. Tesis de Maestría en Ciencias en Computacionales	<ul style="list-style-type: none"> • Playa y mar • Montañas • Bosques • Ríos • Lagos • Desiertos • Flores 	5,195

Tabla 2.3 Problemas con imágenes de prueba

Categorías	Problemas
Flores	<ul style="list-style-type: none"> • Variedad de flores • Variedad en la tonalidad de un tipo en específico de flor • Variedad en la forma de un tipo en específico de flor • Irregularidad de la flor en las partes del mismo objeto
Césped	<ul style="list-style-type: none"> • Variedad en la tonalidad • Variedad en la forma y tamaño • Irregularidad del césped en distintas partes del mismo objeto • Al presentar un tamaño grande de sus elementos tiende a confundirse con la clase árbol
Montañas	<ul style="list-style-type: none"> • Variedad en la tonalidad • Variedad en la forma y tamaño • Existencia de más clases en la categoría montañas como: árboles, césped y nieve • Irregularidad de la montaña en las partes del mismo objeto

2.4 Propuesta solución

Para cumplir con el objetivo planteado en esta tesis, se propone resolver el problema siguiendo los pasos de un modelo que se compone principalmente de 2 etapas: la primera concerniente al tratamiento del paradigma pulsante y las ecuaciones aplicadas para la extracción de características; la segunda referente a la aplicación de las métricas de semejanza.

Para realizar el tratamiento de las imágenes se desarrollan procedimientos que permiten convertirlas en información compatible con las técnicas a implementar. Los procedimientos dependen del modelo matemático aplicado, pero la entrada para los paradigmas presentados en esta tesis son las imágenes principales a color que son convertidas a imágenes a escala de grises.

2.5 Discusión

Después de realizar la revisión de los trabajos relacionados desarrollados tanto en el CENIDET como en el extranjero, la presente propuesta de tesis abre este promisorio campo de estudio de RNPs para la extracción de características.

Aunque en el trabajo de [Cardenas, 2015] también se aplican las RNPs, el dominio abordado ahí es en la detección de bordes y regiones; en cambio, en el presente trabajo, el dominio es la obtención de "Firmas" o huellas de una imagen digital que son formadas a través del total de unos que forman las imágenes binarias que la RNP procesa (características o descriptores).

Esta revisión del estado del arte indica que el modelo de RNP es útil para el procesamiento de imágenes en el área de extracción de características de imágenes. Los problemas que existen para determinar los parámetros correctos, como menciona [Wei, 2011], no permiten explotar con

certeza el buen funcionamiento de la Red. Las simplificaciones al método [Shi, 2007] y las variantes como en [Xiao, 2009], permiten mejorar los resultados o de alguna manera optimizar la metodología *PCNN*. Se encontró que las Redes Pulso Acopladas *ICM* están siendo utilizadas para trabajar con imágenes médicas y que ha sido un buen mecanismo para lograr que parásitos puedan ser reconocidos rápidamente [Kinser, 2004]. Las Redes Pulso Acopladas *SCM* según la literatura prometen extraer características de las imágenes digitales con una reducción en el modelo matemático, reduciendo memoria computacional.

Aún se siguen estudiando las variantes de *PCNN* para la extracción de características de imágenes digitales y se siguen comparando los resultados contra otras técnicas de extracción de características tradicionales tales como momentos invariantes [Hu, 1962], descomposición de rango, características vs *templates*, *template matching*, media, moda, mediana de la imagen, al igual que los tiempos de procesamiento entre una metodología y otra.

El avance de nuevos descubrimientos y formas de conectar una RNP hace que surjan nuevos modelos, cada uno con diferentes mejoras según su propósito u objetivo, lo cual abre posibilidades de mejorar los algoritmos.

La presente tesis busca evaluar a las RNPs cuando son aplicadas al problema de extracción de características, con el fin de obtener información sobre las ventajas y desventajas de este tipo de Redes y determinar su utilidad práctica, en particular para futuros trabajos de investigación en CENIDET.

Capítulo III

Marco Conceptual

En este capítulo se describen los conceptos generales necesarios para llevar a cabo el proyecto de tesis. Se mencionan y describen los temas principales, desarrollados del más general al más particular. Los tópicos a tratar son: *Elementos de las Redes Neuronales Artificiales*, *Visión Artificial (VA)*, *Redes Neuronales Pulsantes (RNPs)*, *Extracción de características*.

3.1 Elementos de las Redes Neuronales Artificiales (RNAs)

3.1.1 La neurona biológica

Una RNA es un modelo matemático inspirado en el comportamiento biológico de las neuronas. Existen tareas muy complejas, como el reconocimiento y clasificación de patrones, que demandan tiempo y esfuerzo aún en los dispositivos más potentes y en donde el cerebro humano es más apto para resolver dichas tareas, a veces sin aparente esfuerzo.

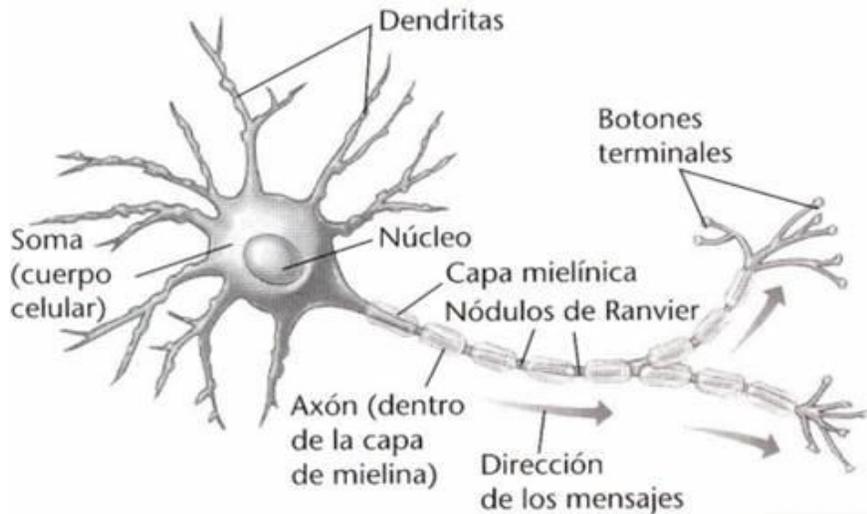


Figura 3.1 Neurona biológica y sus partes principales

Se estima que hay 26,000 millones (2.6×10^{10}) de neuronas en el cerebro humano. El tamaño y forma de las neuronas es variable, pero todas poseen las mismas subdivisiones anatómicas [Delgado, 1998].

La Figura 3.1 [Marrero, 2007] muestra un esquema simplificado de un tipo particular de neurona biológica común, compuesta por: Soma, Dendritas, Axón, Sinapsis. Soma es el cuerpo que contiene el núcleo y se encarga de las actividades metabólicas de la neurona y recibe información de otras neuronas a través de sinapsis.

Dendritas que se especializan en la recepción de señales de otras células nerviosas por medio de conexiones sinápticas.

El Axón es quien permite enviar impulsos a otras células nerviosas. Cuando el axón está cerca de sus células destino se divide en muchas ramificaciones que forman sinapsis con el soma o axones de otras células.

Sinapsis es la conexión entre dos células nerviosas. Las sinapsis pueden ser excitatorias o inhibitorias según el neurotransmisor que se libere; la neurona recibe aproximadamente de 10,000 a 100,000 sinapsis y su axón realiza una cantidad similar de sinapsis.

Las señales se propagan de una neurona a otra mediante una reacción electroquímica. Las sinapsis liberan sustancias químicas transmisoras y entran a la dendrita, con lo cual se eleva el potencial eléctrico del cuerpo de la célula. Una vez que se rebasa un cierto límite, se envía al axón un impulso eléctrico. El impulso se difunde a través de las ramas del axón llegando finalmente a la sinapsis y liberando transmisores en los cuerpos de otras neuronas. Las sinapsis que aumentan el potencial se conocen como *excitadoras* y las que lo disminuyen como *inhibidoras*. Estos mecanismos constituyen el fundamento del aprendizaje en el cerebro.

3.1.2 Redes Neuronales Artificiales

Las RNAs (*Redes Neuronales Artificiales*) son sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas [Montaño, 2002]. Consisten en un conjunto de elementos simples de procesamiento llamados nodos o neuronas conectadas entre sí por conexiones que tienen un valor numérico modificable llamado peso. Los valores de las entradas que recibe de otras unidades conectadas a ella se suman, para comparar esta cantidad con el valor de umbral y si lo iguala o supera envía la activación o salida a las unidades conectadas. Tanto las entradas que la unidad recibe como las salidas que envía dependen a su vez del peso o fuerza de las conexiones por las cuales se realizan dichas operaciones [Delgado, 1998] (ver Figura 3.2)

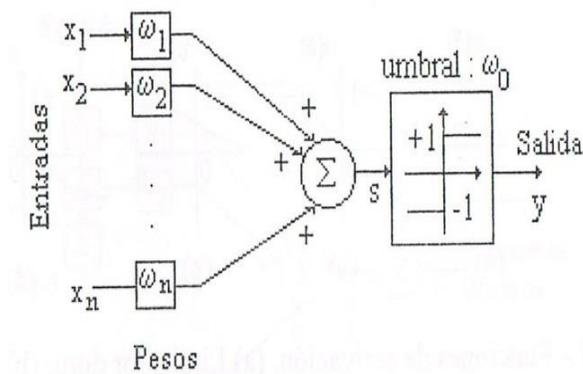


Figura 3.2 Modelo simplificado de la Neurona

Las entradas son $x_i, i=1, \dots, n$, las sinapsis se modelan por los pesos w_i . La neurona se dispara si la suma ponderada de las entradas excede el valor umbral w_0 , en este caso la salida de la neurona toma uno de los dos valores (-1, +1). En notación matemática. Ecuaciones 3.1 y 3.2

$$y = \sigma(\sum_{i=1}^n w_i \cdot x_i + w_0) \quad (3.1)$$

$$\sigma(\theta) = \begin{cases} -1, & \theta < 0 \\ +1, & \theta \geq 0 \end{cases} \quad (3.2)$$

La función $\sigma(\theta)$ se denomina función de activación [Delgado, 1998]. Estas redes surgieron a partir de las ideas en la publicación de [McCulloch, 1943] [Rumelhart, 1986] porque se postula que las neuronas funcionan como dispositivos booleanos. Este postulado fue criticado como teoría biológica, pero permitió generar una neurona como un modelo lineal seguido de una función de activación booleana. Aquí, la función lineal representa la sinapsis (unión entre neuronas) y la agregación de la información, mientras que la función no lineal (limitador duro, umbral lógico o función escalón) representa el procesamiento que hace la neurona.

Este tipo de redes, debido a las características mencionadas, pertenece a la primera generación de RNAs. El *Perceptron* fue el primer modelo de red neuronal, el cual utiliza básicamente la neurona artificial de la Figura 3.3

El mayor problema con el *Perceptron* es que no puede resolver problemas no lineales (por ejemplo, XOR). La combinación de varios perceptrones simples podría resolver ciertos problemas no lineales pero no existía un mecanismo automático para adaptar los pesos de la capa oculta.

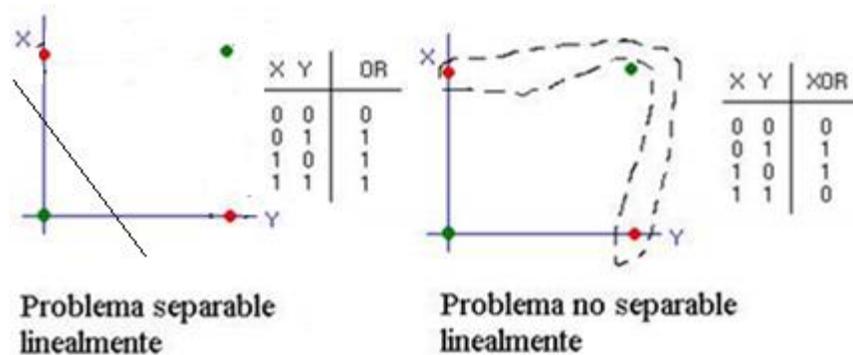


Figura 3.3 Problema separable linealmente y problema no separable linealmente

Luego del *Perceptron*, surge la segunda generación de RNAs con funciones de activación continuas, tales como la sigmoide, funciones de base radial, función logística y tangente hiperbólica. Un ejemplo de este tipo de red es el *Multi-Layer Perceptron* (MLP) con algoritmo de *Backpropagation* (BP), ya que la salida no es binaria sino continua. El MLP puede ser totalmente o localmente conectado (ver Figura 3.4). En el primer caso cada salida de una neurona de la capa "i" es entrada de todas las neuronas de la capa "i+1", mientras que en el segundo cada neurona de la capa "i" es entrada de una serie de neuronas (región) de la capa "i+1".

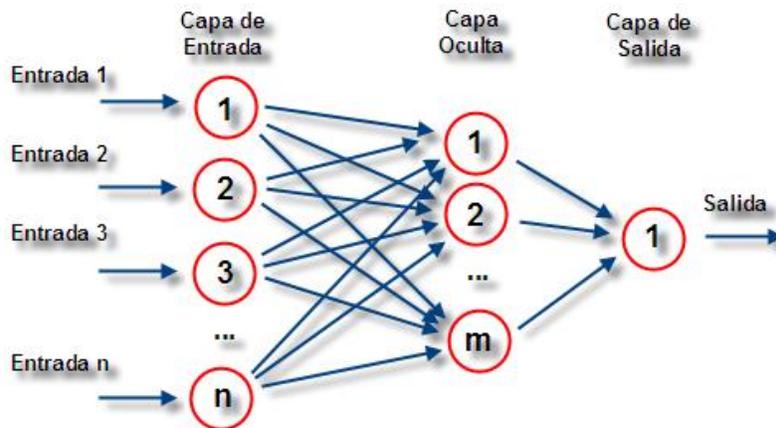


Figura 3.4 Diagrama del *Multi-Layer Perceptron*

Rumelhart y otros autores, en 1986, presentan la "Regla Delta Generalizada" para adaptar los pesos propagando los errores hacia atrás, es decir, propagar los errores hacia las capas ocultas inferiores. *Multi-Layer Perceptron* puede aproximar relaciones no lineales entre los datos de entrada y salida (Figura 3.5).

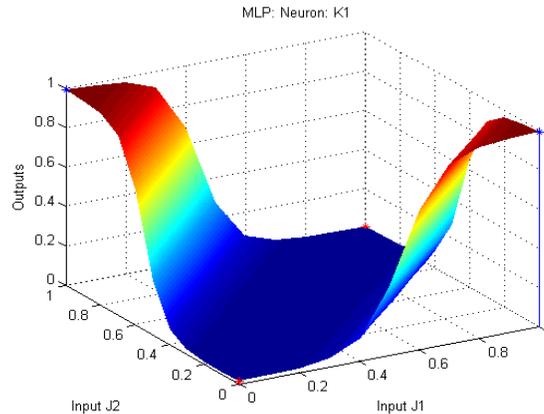


Figura 3.5 Salida (Híper-plano) del MLP para XOR

La tercera generación corresponde a las RNAs Pulsantes, las cuales serán descritas en la sección 3.3 y son el tema central de la presente propuesta de tesis.

Como se ha mencionado existen modelos muy diversos de RNAs en los cuales se siguen filosofías de diseño, reglas de aprendizaje y funciones de construcción de las respuestas muy distintas. Otra clasificación sería atendiendo al tipo de entradas y otra de acuerdo al mecanismo de aprendizaje.

Ventajas

Debido a su constitución y a sus fundamentos, las RNAs presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar a partir de casos de entrenamiento, de abstraer características esenciales a partir de entradas que podrían contener información irrelevante, etc. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Entre las ventajas se pueden citar las siguientes [Meneses, 2008]: *Aprendizaje Adaptativo*, *Auto-organización*, *Tolerancia a fallos*, *Procesamiento Paralelo*.

Aprendizaje Adaptativo: La capacidad de aprendizaje adaptativo es una de las características atractivas de las RNAs. Aprenden a llevar a cabo ciertas tareas mediante un entrenamiento con ejemplos ilustrativos. No es necesario elaborar modelos *a priori* ni especificar funciones de distribución de probabilidad. Son sistemas dinámicos auto-adaptativos. Son adaptables debido a

la capacidad de auto-ajuste de sus elementos. Son dinámicos porque son capaces de estar constantemente cambiando para adaptarse o ajustarse a las nuevas condiciones. La función del diseñador humano se limita a la obtención de la arquitectura apropiada. Es necesario que se aplique un adecuado algoritmo de aprendizaje que le proporcione a la red la capacidad de discriminar, mediante un entrenamiento con patrones.

Auto-organización: Las redes neuronales emplean su capacidad de aprendizaje adaptativo para auto-organizar la información que reciben durante el aprendizaje y/o la operación. Mientras que el aprendizaje es la modificación de cada elemento procesado, la auto-organización consiste en la modificación de la red neuronal completa para llevar a cabo un objetivo específico.

Cuando las redes neuronales se usan para reconocer ciertas clases de patrones, ellas auto-organizan la información usada. Esta auto-organización provoca la *generalización*: facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones en las que no había sido expuesta anteriormente. El sistema puede generalizar la entrada para obtener una respuesta.

Tolerancia a fallos: Las redes neuronales fueron los primeros métodos computacionales con la capacidad inherente de tolerancia a fallos. Haciendo una comparación con los Sistemas Computacionales tradicionales, los cuales pierden su funcionalidad cuando sufre un pequeño error de memoria, en las RNAs, si se produce un fallo en un número no muy grande de neuronas, el comportamiento del sistema no sufre una caída repentina.

Hay dos aspectos distintos respecto a la tolerancia a fallos:

- 1) Las redes pueden aprender a reconocer patrones con ruido, distorsionados o incompletos. Esta es una tolerancia a fallos respecto a los datos.
- 2) Las redes pueden seguir realizando su función (con cierta degradación) aunque se destruya parte de la red.

Procesamiento en Paralelo: Una de las mayores prioridades, es la necesidad de realizar procesos con datos de forma muy rápida. Las redes neuronales se adaptan bien a esto debido a su arquitectura paralela. Para que la mayoría de las redes puedan operar en un entorno de tiempo real, la necesidad de cambio en los pesos de las conexiones o entrenamiento puede ser minimizada debido al paralelismo implícito.

Desventajas

Es conveniente describir las desventajas que presentan las RNAs, ya que de esta manera permitirán un contexto más general de lo que son y no capaces de realizar. Entre las desventajas más notorias [Esaa, 2010] los describe: *Consumo de recurso, Las RNAs no dan explicación de su salida, Etapa Temprana de Desarrollo, PC's Secuenciales, Ajuste de Parámetro, Modelos Primitivos.*

Consumo de recursos: Las redes neuronales se deben entrenar para cada problema. Además, es necesario realizar múltiples pruebas para determinar la arquitectura adecuada.

Las RNAs no dan explicación de su salida: Las redes neuronales presentan un aspecto complejo para un observador externo que desee realizar cambios ya que en general se comportan como “cajas negras”.

Etapas Tempranas de Desarrollo: Las RNAs se encuentran en una etapa temprana de desarrollo, el inicio de la tecnología tendrá apenas alrededor de 50 años, por lo cual aún no se puede considerar una tecnología madura.

PC's Secuenciales: La capacidad de las redes neuronales radica en su habilidad de procesar información en paralelo. Pero, las máquinas más accesibles son en serie (sólo ejecutan una instrucción a la vez) por lo que, modelar procesos paralelos en máquinas serie, lleva más tiempo, dinero y esfuerzo.

Ajuste de Parámetros: Debido a que las redes se entrenan en lugar de programarse, requieren la definición y ajuste de parámetros antes de poder aplicar la metodología para poder obtener los resultados esperados. Por ejemplo hay que decidir la arquitectura más apropiada, el número de capas ocultas (si fuese necesario), el número de neuronas por capa, las interconexiones, la función de activación, la tolerancia, la tasa de aprendizaje, los pesos iniciales, etc. todo lo cual se ajusta típicamente siguiendo un proceso de prueba y error.

Modelos Primitivos: Debido a que no se conoce mucho sobre el funcionamiento del cerebro humano o biológico aún queda bastante campo dentro de la investigación, por lo que al considerar que las redes neuronales son una analogía con las redes del cerebro humano, ocasiona que los modelos que emulan este funcionamiento sean de alguna manera limitados actualmente.

3.2 Visión Artificial (VA)

La percepción visual humana es un concepto importante en el desarrollo del paradigma pulsante, puesto que el objetivo de este paradigma es replicar el funcionamiento de las neuronas de la corteza visual tal y como lo haría la visión humana.

La visión humana

Para entender cómo los humanos perciben las imágenes es necesario saber acerca de la anatomía básica de la vista humana. La complejidad de la visión humana comienza desde que los ojos están conectados con regiones especializadas en el cerebro, Figura 3.6 [Gonzales, 2006]

- Capturar la radiación electromagnética (400-700 nanómetros de la longitud de onda) reflejada por los objetos de la escena.
- Codificar la luz por medio de reacciones electroquímicas.
- Transmitir la correspondiente señal eléctrica por medio del nervio óptico hasta el cerebro.
- Las señales visuales son transmitidas por dos caminos visuales paralelos que llevan desde la retina hasta la corteza visual.

El sistema visual

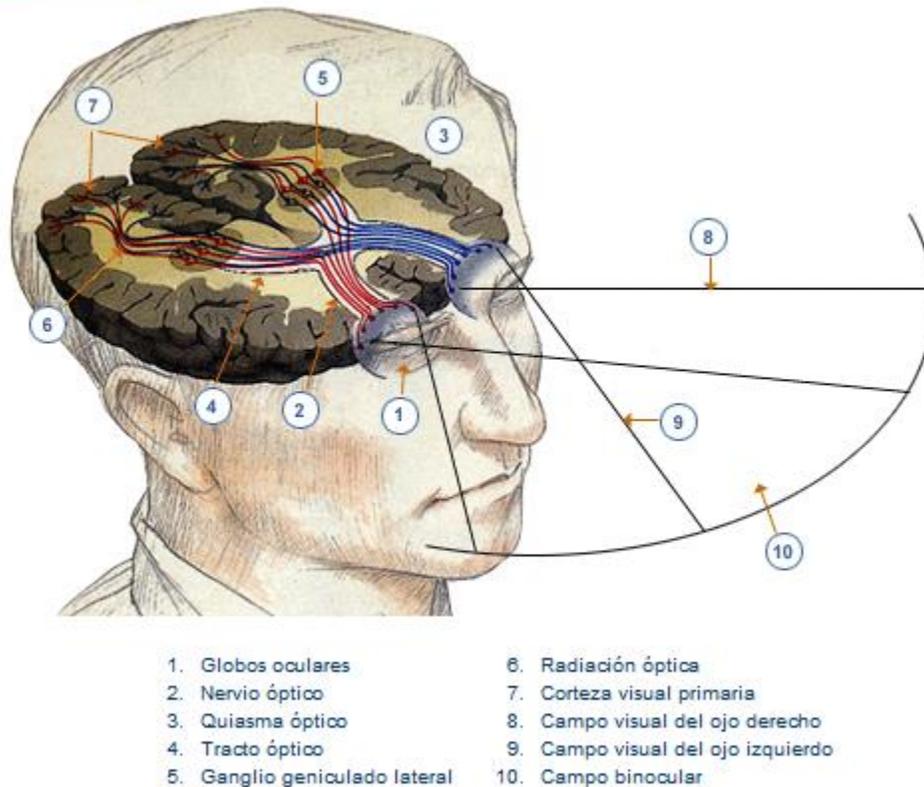


Figura 3.6 Vista simplificada del proceso de conexión de la vista con el cerebro

La VA es una técnica basada en la adquisición de imágenes para procesarlas digitalmente con el fin de extraer y medir determinadas propiedades de las imágenes adquiridas, de forma equivalente a la inspección visual humana [González, 2006].

Los pasos más comunes del análisis o procesamiento de imágenes [González, 2006], [Ramírez, 2011], [Marques, 2011] se muestran en la Figura 3.7

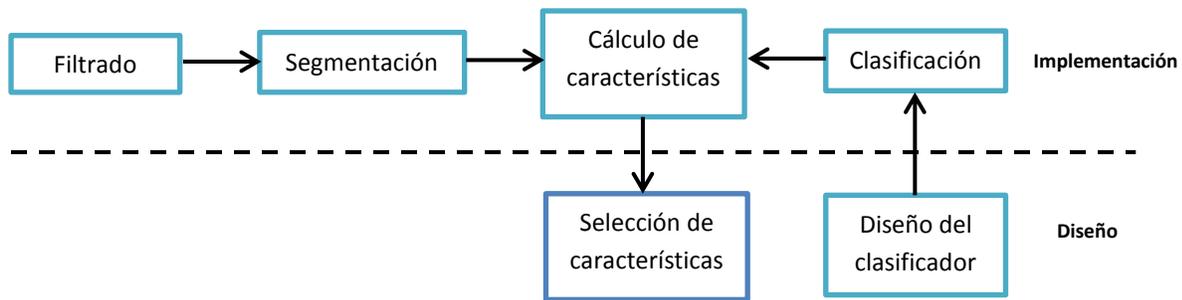


Figura 3.7 El proceso de la Visión Artificial

- Filtrado o pre-procesamiento: Corrección de defectos.
- Segmentación o aislamiento de los objetos de interés: Separación de objetos de interés, se pretende detectar los bordes entre los elementos o regiones.
- Extracción y selección de características: Con los objetos de interés se extraen las medidas de sus características en forma de vectores.
- Reconocimiento de formas e Inteligencia Artificial: A partir de los vectores de entrada se utiliza un clasificador para obtener las conclusiones posibles.

3.3 Paradigma Red Neuronal Pulsante (RNP)

Las RNPs se pueden considerar como la tercera generación de RNAs; la primera generación son las RNAs basadas en el modelo de dos clases (como el *Perceptron*) y la segunda generación comprende a los paradigmas donde las neuronas cuentan con funciones de activación continuas (como el *Multilayer Perceptron*, MLP), y por lo tanto son capaces de manejar múltiples clases.

La principal diferencia las RNPs con respecto a las dos generaciones anteriores es que es un paradigma cuyas neuronas son activadas no sólo por valores numéricos, sino además por pulsos o señales externas. Esta red ha sido utilizada para el pre-procesamiento de imágenes desarrollada por Eckhorn en 1989 [Chacon, 2011] a partir de la corteza visual del cerebro del gato. La RNP es implementada en un modelo de una neurona por píxel y su arquitectura tiene tres módulos: el módulo dendritas (*Entrada*), el módulo de encadenamiento L (*Linking*) y el generador de pulsos (*Generador de Pulsos*). El árbol de dendritas recibe la información del vecindario y se procesa en el módulo de encadenamiento y alimentación *F* (*Feeding*), otra parte de la red que también contiene la entrada. El generador de pulsos tiene un umbral dinámico *T*

que se basa en el proceso interno que tiene la neurona en el módulo de alimentación y el módulo de Encadenamiento (ver Figura 3.8).

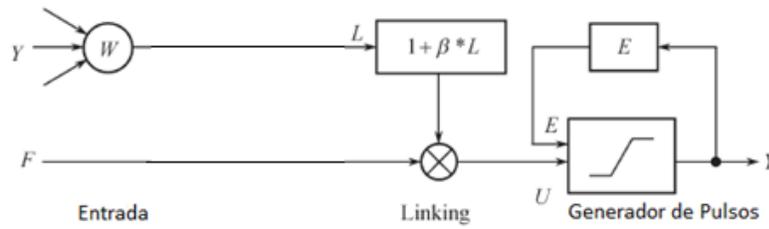


Figura 3.8 Modelo del campo de Vinculación

Una RNP está definida por varias ecuaciones que describen el proceso de alimentación o *feeding*, la actividad de enlace entre neuronas y sus interconexiones, así como el valor del umbral y la salida. Está compuesta de una única capa bi-dimensional. En el pre-procesamiento de imágenes se tiene una correspondencia 1:1 entre los pixeles de la imagen y las neuronas de la red como se muestra en la Figura 3.9

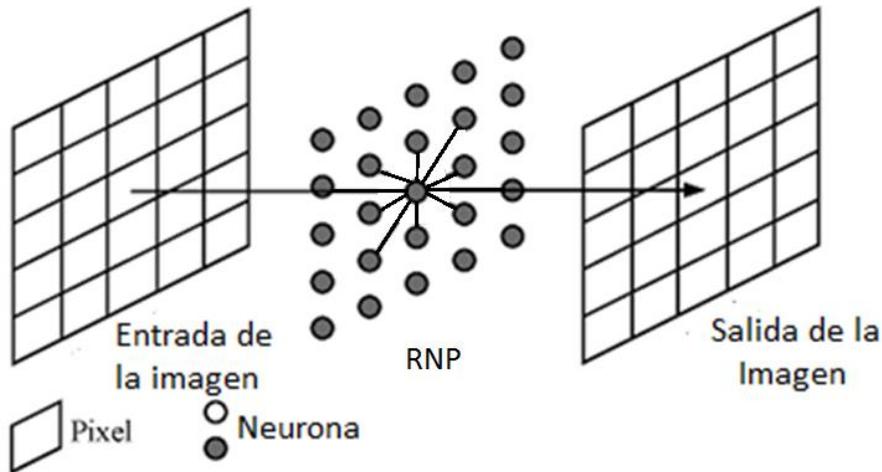


Figura 3.9 Modelo de conexión de una sola neurona PCNN

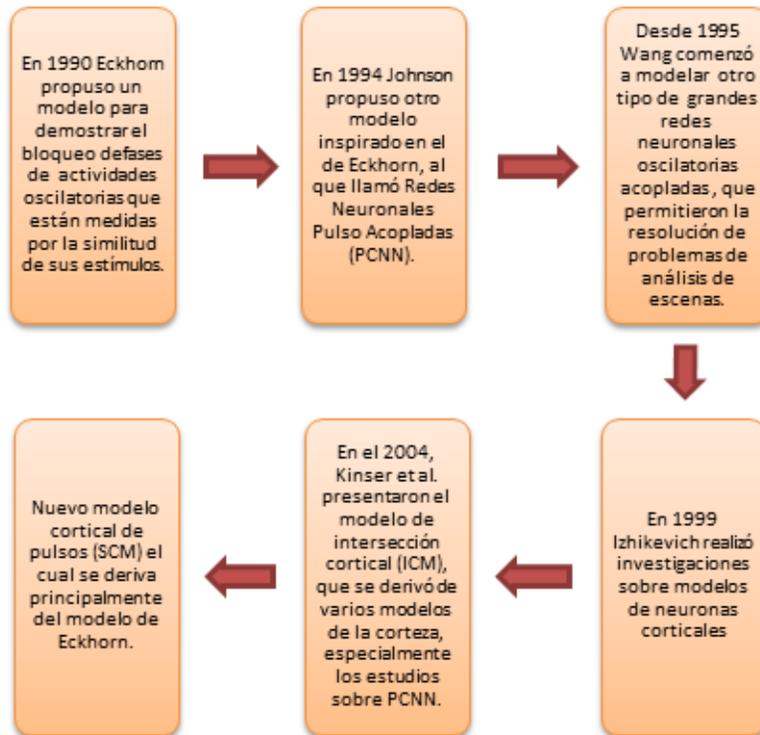


Figura 3.10 Origen y variantes de las RNPs [Cárdenas, 2015]

Los modelos de RNP están contribuyendo en las áreas del procesamiento de imágenes como segmentación, eliminación de ruido, detección de objetos y extracción de características debido su capacidad de pre-procesamiento, según los estudios realizados por [Wang, 2010].

En la Figura 3.10 se puede observar el origen y las variantes de las RNPs, así como el propósito con el que fueron creadas [Zhan, 2009].

[Johnson, 1994] observó que las RNPs pueden generar para cada entrada de una imagen su propia y única firma de serie de tiempo. De acuerdo a esta observación las RNPs podrían reconocer con éxito la imagen que fue contaminada por ruido o que fue rotada, trasladada e incluso escalada.

En otras palabras Johnson descubrió la facilidad que tienen las RNPs para extraer características porque determinó que la salida de las imágenes pulsantes de una RNP podría ser reconocida aún con cambios de rotación, escala o traslación. En otro trabajo [Ma, 2010] presenta un experimento para el reconocimiento de imágenes afectadas por ruido, dada la imagen original y la imagen afectada por ruido y hace uso de una RNP para obtener una “Firma” o huella de las imágenes y así extraer características independientes de la misma imagen.

3.4 Modelo Matemático de las RNPs

Las RNPs, son un modelo simplificado real de las células neuronales biológicas, por supuesto, también tiene muchos aspectos que hay que tener en cuenta, tales como la esperanza de vida real de las células vivas, la edad, y la temperatura, entre otras. Por lo tanto, con el desarrollo de la biología, el papel desempeñado por las RNPs será más y más importante en el campo de procesamiento de imágenes [Ma, 2010].

El modelo se muestra en la Figura 3.11. La RNP acepta la entrada del *Feeding* (F) y la entrada de *Linking* (L), estos generan una actividad interna U . Cuando U es mayor que el Umbral dinámico E , la RNP produce una secuencia de pulsos Y [Liu, 2010][Zhang, 2012].

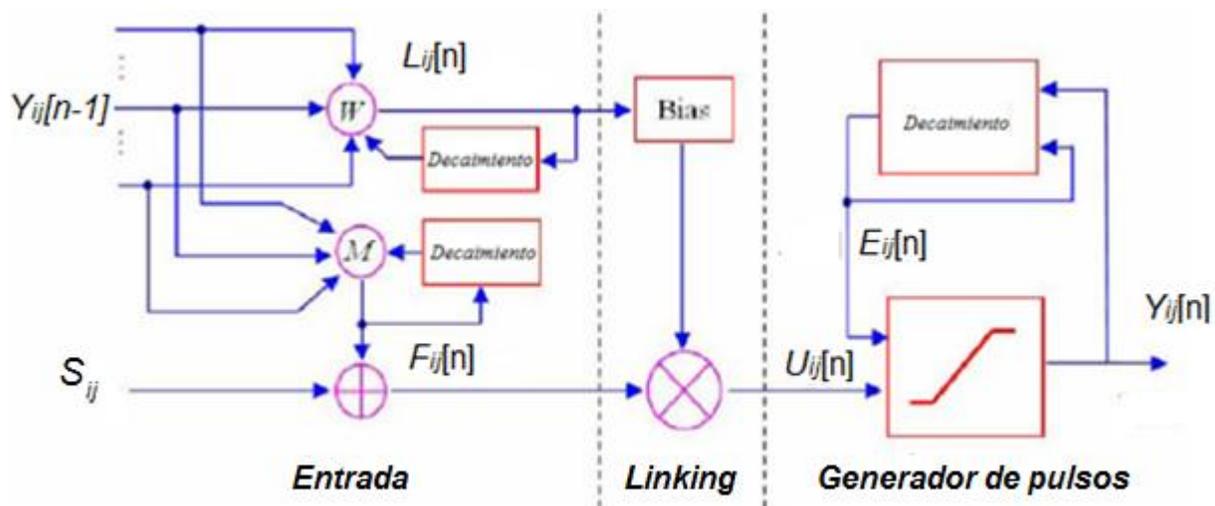


Figura 3.11. Modelo Linking

La RNP tiene prácticamente una capa bi-dimensional de neuronas pulso acopladas, la cual está conectada con todos los pixeles de una imagen. Es decir, cada pixel es asociado con una neurona de la Red Neuronal Pulsante, así la estructura de la RNP da como salida otra estructura para la siguiente entrada de la imagen que será procesada.

3.4.1 Pulse Coupled Neuronal Network (PCNN)

La Figura 3.11 muestra una neurona de una PCNN [Zhang, 2012], donde acepta como entrada el *Feeding* (F) y la entrada de *Linking* (L), generando un estado interno U . Cuando U es

mayor que un umbral dinámico la PCNN produce secuencialmente pulsos. El modelo es el siguiente:

$$F_{ij}[n] = e^{-\alpha_F} F_{ij}[n - 1] + V_F \sum_{kl} M_{ijkl} Y_{kl}[n - 1] + S_{ij}; \quad (3.3)$$

$$L_{ij}[n] = e^{-\alpha_L} L_{ij}[n - 1] + V_L \sum_{kl} W_{ijkl} Y_{kl}[n - 1]; \quad (3.4)$$

$$U_{ij}[n] = F_{ij}[n](1 + \beta L_{ij}[n]); \quad (3.5)$$

$$E_{ij}[n] = e^{-\alpha_E} E_{ij}[n - 1] + V_E Y_{ij}[n - 1]; \quad (3.6)$$

$$Y_{ij}[n] = \begin{cases} 1 & U_{ij}[n] > E_{ij}[n] \\ 0 & \text{Otro caso} \end{cases} \quad (3.7)$$

F_{ij} , Feeding; U_{ij} , Actividad Interna; L_{ij} , Linking; E_{ij} , Umbral Dinámico; Y_{ij} , salida de PCNN (0 - 1); $\alpha_F, \alpha_L, \alpha_E$; constantes para el tiempo de decaimiento, V_F ; las magnitud del dominio del feedback, V_L ; Acoplamiento de dominio de conexión, V_E ; magnitud de ajuste Umbral dinámico, β ; Coeficiente de conexión de las actividades internas, M_{ijkl} y W_{ijkl} ; pesos de las matrices del dominio de entrada del feeding y el dominio de la conexión de acoplamiento, respectivamente.

Cada neurona es denotada con los índices (i,j) y sus neuronas vecinas son denotadas con los índices (k,l) . Feeding (F) es combinado con el Linking (L) como una actividad interna U de la neurona. La neurona recibe de entrada vía Feeding y la sinapsis M , y cada neurona es conectada con sus vecinos, por lo tanto la salida de la neurona modula la actividad de sus vecinos vía Linking y la sinapsis W . El Pulso es retroalimentado para modular el Umbral E . La magnitud del Umbral incrementa con V_E y decrementa con la constante α_E . Cuando la actividad interna U de la neurona excede el umbral dinámico E , un pulso es generado.



Figura 3.12. a) Representación esquematizada de la Actividad Interna sin estímulos inducidos. b). Representación esquematizada del Umbral dinámico mientras no ocurren pulsos

Combinando las Figuras 3.12 (salidas a y b) [Ma, 2010] se puede obtener la salida pulsante de la RNP (Figura 3.13).

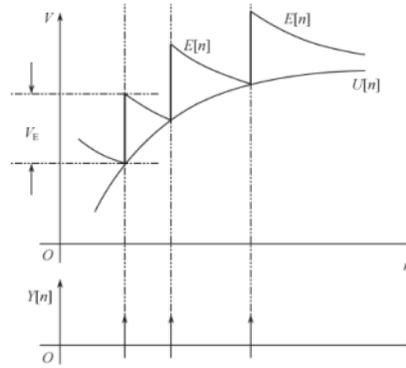


Figura 3.13. Representación esquematizada de la salida de una RNP sin estímulos inducidos

La Figura 3.14 [Ma, 2010] muestra el comportamiento de cada una de las salidas de las ecuaciones (3.3),(3.4),(3.5),(3.6),(3.7), para una neurona mostrando la forma en que la red genera los pulsos.

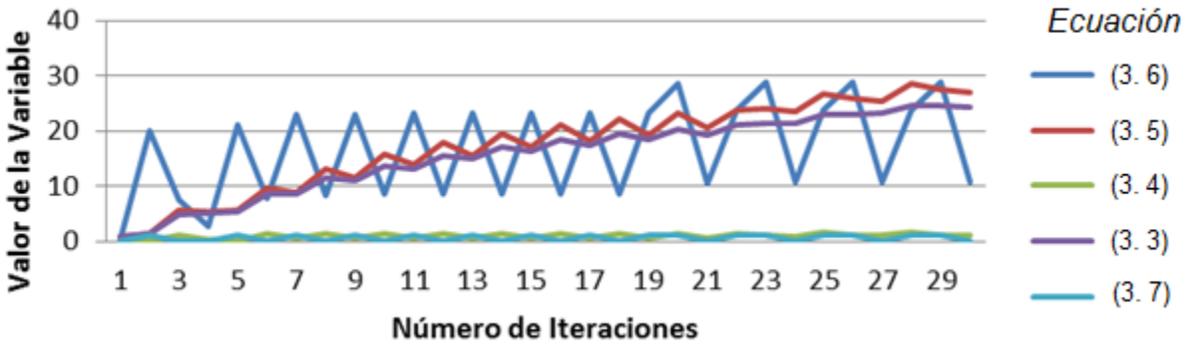


Figura 3.14 Salida de una neurona pulsante

La RNP es un modelo digital en base a un solo modelo biológico. Cabe indicar que hay varios modelos biológicos que se han propuesto. Estos modelos son matemáticamente similares al sistema de Fitzhugh-Nagumo [Fitz, 1961] [Nagumo, 1962] en que cada neurona consta de osciladores acoplados. Cuando el objetivo es la creación de una imagen en la aplicación del procesamiento ya no es necesario replicar exactamente el sistema biológico. La contribución importante del modelo cortical es extraer la información de la imagen y no hay que preocuparse en cuanto a un modelo biológico único [Lindblad, 2005].

Los modelos descritos a continuación tratan de minimizar el costo de cálculo, pero mantienen la eficacia del modelo cortical cuando se aplica a las imágenes.

Su fundamento se basa en los elementos comunes de varios modelos biológicos.

3.4.2 Intersecting Cortical Model (ICM)

El Modelo ICM por sus siglas en inglés *Intersecting Cortical Model* es un modelo simplificado de la PCNN [Ekblad, 2004], es un caso especial de la PCNN cuando no hay *Linking* entre las neuronas, sólo tiene entradas el *Feeding*, así si la intensidad de la vinculación de la PCNN está ajustado a 0 entonces se convertirá en un ICM.

Por lo tanto, el sistema consta de dos osciladores acoplados, un número de conexiones, y una función no lineal. Ecuaciones 3.8 – 3.10

$$F_{ij}[n] = f F_{ij}[n-1] + \sum_{kl} M_{ijkl} Y_{kl}[n-1] + S_{ij} \quad (3.8)$$

$$E_{ij}[n] = g E_{ij}[n-1] + h Y_{ij}[n-1] \quad (3.9)$$

$$Y_{ij}[n] = \begin{cases} 1 & F_{ij}[n] > E_{ij}[n] \\ 0 & \text{Otro caso} \end{cases} \quad (3.10)$$

F_{ij} , Entrada *Feedback* (Input); E_{ij} , Umbral Dinámico; Y_{ij} , La salida de PCNN (0 - 1); S_{ij} , Imagen de entrada; f , g , constantes de decaimiento (valores menores a 1, necesarios para asegurar que el umbral decaiga con el tiempo y se generen los impulsos neuronales); h , magnitud de escalamiento para Y (es un valor grande que aumenta dramáticamente el umbral cuando la neurona se dispara); M_{ijkl} , son los pesos de las matrices del dominio de entrada del *Feeding* y el dominio de la conexión de acoplamiento, respectivamente cae por debajo del estado y los impulsos neuronales.

El modelo se comporta de forma muy similar a la PCNN, es decir cada neurona es denotada con los índices (i,j) y las neuronas vecinas con los índices (k,l) . La información que se desea de estos sistemas es la extracción de información de la imagen. Se desea tener las imágenes de pulso que muestran los segmentos, bordes, y texturas que son inherentes en la imagen de entrada.

Los principales cambios son:

- Se elimina el factor de decaimiento $e^{-\alpha F}$, sustituido por f .
- El ajuste V_f es eliminado y $L_{ij}[n]$ es eliminado.
- Se elimina el factor de decaimiento $e^{-\alpha E}$, sustituido por g .
- El ajuste V_E es eliminado, sustituido por h .

3.4.3 Spiking Cortical Model (SCM)

El Modelo SCM por sus siglas en inglés *Spiking Cortical Model* es un modelo simplificado de la RNP [Ma, 2010] (Ecuaciones 3.11 - 3.13)

Las Neuronas reciben la señal de la entrada vía sinapsis *Feeding* y cada neurona es conectada a sus vecinos de tal manera la señal de la salida de una neurona modula la actividad de sus vecinos vía sinapsis *Linking*, por lo tanto el modelo SCM está dado por [Ma, 2010] [Lindblad, 2005].

$$U_{ij}[n] = f U_{ij}[n-1] + S_{ij} \sum_{kl} W_{ijkl} Y_{kl}[n-1] + S_{ij} \quad (3.11)$$

$$E_{ij}[n] = g E_{ij}[n-1] + h Y_{ij}[n-1] \quad (3.12)$$

$$Y_{ij}[n] = \begin{cases} 1 & 1/(1+\exp(-\gamma(U_{ij}[n]-E_{ij}[n]))) > 0.5 \\ 0 & \text{Otro caso} \end{cases} \quad (3.13)$$

U_{ij} , Entrada *Feedback (Input)*; E_{ij} , Umbral Dinámico; Y_{ij} , La salida de PCNN (0 - 1); S_{ij} , Imagen de entrada; f, g , constantes de decaimiento (valores menores a 1, necesarios para asegurar que el umbral decaiga con el tiempo y se generen los impulsos neuronales); h , magnitud de escalamiento para Y (es un valor grande que aumenta dramáticamente el umbral cuando la neurona se dispara); W_{ijkl} , son los pesos de las matrices del dominio de entrada del *Feeding* y el dominio de la conexión de acoplamiento, respectivamente cae por debajo del estado y los impulsos neuronales.

El modelo se comporta de forma muy similar a la PCNN, es decir cada neurona es denotada con los índices (i,j) y las neuronas vecinas con los índices (k,l) . La información que se desea de estos sistemas es la extracción de información de la imagen. Se desea tener las imágenes de pulso que muestran los segmentos, bordes, y texturas que son inherentes en la imagen de entrada.

Los principales cambios son:

- Se elimina el factor de decaimiento $e^{-\alpha F}$, sustituido por f .
- El ajuste V_f es eliminado sustituido por S_{ij} y $L_{ij}[n]$ es eliminado.
- Se elimina el factor de decaimiento $e^{-\alpha E}$, sustituido por g .
- El ajuste V_E es eliminado, sustituido por h .
- Hace uso de la función Sigmoidal para determinar la salida.

3.5 Extracción de características

Las imágenes digitales contienen información importante (características) que son esenciales para el reconocimiento. También es necesario encontrar características que sean invariantes a la rotación y escala, es decir, que el valor numérico de las características sea similar al rotar o escalar. Una característica se define como el elemento capturado de una cierta propiedad visual de una imagen [Datta, 2008] y debe de tener las siguientes particularidades [Chatzichristofis, 2011]:

- 1.- Discriminación. Las características deben ser capaces de diferenciar un objeto de otro.
- 2.- Confiabilidad. Para los objetos similares los valores también tienen que ser similares.
- 3.- Bajo costo computacional. El tiempo de procesamiento depende del tipo de imágenes con que se trabaje.

El grado de independencia de las características se puede tomar de dos enfoques: primero, transformar la imagen, es decir, rotarla y escalarla para hacerla lo más similar posible a un patrón estándar, después de esto se pueden extraer características numéricas de la imagen; un segundo enfoque consiste en trabajar con la imagen tal cual es tomada por la cámara, y utilizar características en las que se obtengan valores numéricos similares para una misma imagen, es decir que sean invariantes a cambios de rotación, escala e iluminación.

Para el reconocimiento es conveniente encontrar métodos de extracción de características que minimicen la pérdida de información, pero que al mismo tiempo sean invariantes a la rotación y a la escala. Los momentos invariantes, como los momentos de [Hu,1962] o de [Flusser, 2000], son características que cumplen dicha propiedad.

También una imagen puede ser analizada como la composición de tres señales de información principales: a) bordes, b) texturas y c) detalles asociados a los bordes. Los bordes representan información de gran valor para el entendimiento de una imagen, por ejemplo los caracteres de texto. Las texturas de fondo representan la información restante después de remover los bordes.

Los bordes son los puntos de alto contraste en una imagen, es decir donde la intensidad de la imagen aumenta o disminuye bruscamente, los detalles asociados a los bordes representan información de color cercana a los lados de los bordes. Los detectores de bordes más utilizados en la literatura son: Canny, Roberts, Sobel, Prewitt y SUSAN, (por las siglas en inglés de *Smallest Univalued Segment Assimilating Nucleus*) este último definido como el mejor método para la obtención del mapa de bordes según [Canny, 1986].

3.6 Extracción de características con una RNP

[Johnson, 1999] descubrió la facilidad de usar las RNP para extraer características y esto podría ser usado para representar de manera única la imagen de entrada. Las imágenes pulsantes son llamadas imágenes binarias porque ellas sólo tienen dos valores 0 ó 1. Las imágenes binarias contienen abundante información de las características de la imagen original, pero no es posible usar todas las imágenes, ya que sería abundante información así es necesario de una transformada de datos que pueda representar a la imagen original.

Por lo tanto se introducirá la aplicación de la RNP en el campo de reconocimiento de patrones, especialmente extrayendo características en base a la RNP. Posteriormente se expresaran otras medidas y medidas estadísticas más eficientes para medir las series de tiempo.

$$G[n] = \sum_{i,j} Y_{i,j}[n] \quad (3.14)$$

donde Y es la imagen de salida de una RNP; los índices (i,j) representan la posición de neurona en la imagen; n es el número de iteración de la RNP, Ecuaciones 3.14 – 3.18.

3.6.1 Series de tiempo

Las series de tiempo de una RNP son un tren de impulsos en función del tiempo (ver Figura 3.15). La señal de tiempo de un objeto especificado en la entrada del *Feeding* de la imagen es un tren de impulsos que emana de todas las neuronas. Las series de tiempo tienen la propiedad deseable de especificar un objeto, siendo insensibles a no sólo todas las distorsiones geométricas conocidas debido a objeciones de un sistema de imagen, sino también insensible a la escena global de iluminación y objetos de articulación. Johnson consideró un tipo de transformada que es un tipo de suma para cada salida binaria de la imagen de la RNP, dando una salida de una serie en una dimensión, la llamó serie de tiempo $G[n]$, (Ecuación 3.14)

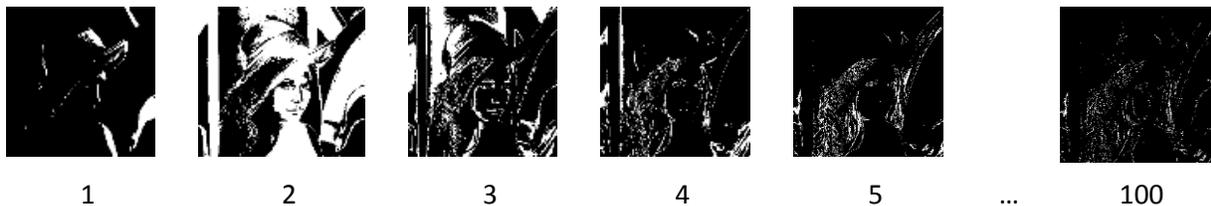


Figura 3.15 Ejemplo de las imágenes binarias de la salida de una RNP (SCM)

Johnson atribuyó que esta serie de tiempo o “Firma” era muy poco invariante a la rotación, escalado y ruido, lo cual lo hace adecuado para la clasificación. Prácticamente $G[n]$ realiza una transformada de una multi-dimensión a una sola dimensión, reduciendo enormemente el poder

computacional y el espacio en memoria. También es posible derivar una nueva serie a partir de la serie de tiempo, como por ejemplo las siguientes [Ma, 2010]:

Serie de Energía de tiempo

$$e1 = \sum_n Y_{i,j}[n]^2 \quad (3.15)$$

Media Residual

$$e2 = \sum_n |Y_{i,j}[n] - \mu| \quad (3.16)$$

donde μ representa la media de la serie de tiempo.

Desviación estándar

$$e3 = \sum_n (Y_{i,j}[n] - \mu)^2 \quad (3.17)$$

donde μ es la esperanza matemática de la imagen de entrada (imagen en escala de grises).

Energía Ponderada (Propuesta)

$$e4 = \sum_{i,j} Y_{i,j}[n] * v \quad (3.18)$$

donde v , representa un peso mayor para las primeras salidas de la serie de tiempo, es decir, es una variable de tamaño n (número de iteraciones de la RNP) que toma el valor de n y descendiente a 0.

3.6.2 Series con entropía

Si se hace una combinación de las series de tiempo con información de entropía se puede representar una nueva señal o “firma” distinta. La entropía es un tipo de representación estadística de las características de una imagen, la cual refleja información que contiene la imagen. Entonces la entropía de una imagen binaria, es decir, $Entropía(Y[n]) = En[n] = H(P)$, como lo muestra la Ecuación 3.19.

Entropía

$$H[p] = -P_1 \log_2 (P_1) - P_0 \log_2 (P_0) \quad (3.19)$$

donde P_1 es la probabilidad de que existan 1's en la imagen binaria y P_0 es la probabilidad de que existan 0's en la imagen binaria [Ma, 2010]. Similar a $G[n]$, $H[p]$, la salida de la entropía de las imágenes binarias es un tipo de serie de tiempo. También esta serie de tiempo es invariable a

la rotación, escalamiento y ruido. Y algunas formas para extraer las características derivadas de la entropía (Ecuación 3.19) se incluyen la energía logarítmica, logarítmica, energía entrópica (Ecuaciones 3.20 – 3.22).

Energía logarítmica

$$e5 = -\sum_n P^2 \times \log_2 P^2 \quad (3.20)$$

Logarítmica

$$e6 = -\sum_n \log_2 P \quad (3.21)$$

Energía entrópica

$$e7 = -\sum_n \log_2 P^2 \quad (3.22)$$

3.7 Mediciones

La medida de similitud, función de distancia o simplemente distancia, es un factor importante para conocer la relación de emparejamiento con otras firmas o series de tiempo. Esto es medir la distancia que existe entre dos puntos (característica), una del ejemplo contra cada imagen de una base de datos. La elección de una medida de similitud está relacionado con los datos extraídos de la imagen (firma o serie de tiempo) por lo tanto se realizó una búsqueda de distintas medidas de similitud.

De este tipo de métricas se encuentran dos tipos [Chatzichristofis, 2011]: similitud y disimilitud. Se habla de una medida de similitud cuando las imágenes son idénticas y la distancia es 0, y 1 en el otro caso, esto es cuando la salida está normalizada.

Siguiendo la idea de [Lux, 2013], la medida es una función $d : X * X \rightarrow IR$ para $x,y,z \in X$ (es decir, el cuadrado de un conjunto de X que contiene los elementos x,y,z y pertenecen a los números reales) que especifica las siguientes propiedades:

- 1.- No negatividad: $d(x,y) \geq 0$
- 2.- Identidad: $d(x,x) = 0$
- 3.- Simetría: $d(x,y) = d(y,x)$
- 4.- Desigualdad triangular: $d(x,z) \leq d(x,y) + d(y,z)$

A continuación se describirán las medidas de similitud más representativas en recuperación de imágenes y similitud de series de tiempo.

Métrica Minkowski: Esta es la métrica más usada para determinar similitud entre dos características y se define como sigue, Ecuación 3.23

$$d_p(i, j) = (\sum_{k=1}^m |x_{ik} - x_{jk}|^p)^{\frac{1}{p}} \quad (3.23)$$

donde: p , es el orden de la distancia; x es la tupla de 2 filas para el cálculo de la distancia entre sus filas; (i, j) son los índices de las filas de la distancia a calcular; m es la dimensión de la tupla; k es el índice de los elementos de la tupla. De esta medida se desprenden tres técnicas:

Distancia Manhattan: La distancia es tomada como la suma absoluta de las diferencias entre los elementos a comparar, Ecuación 3.24

$$d(i, j) = \sum_{k=1}^m |x_{ik} - x_{jk}| \quad (3.24)$$

donde: x es la tupla de 2 filas para el cálculo de la distancia entre sus filas; para el cálculo de la distancia entre sus filas; (i, j) son m es la dimensión de la tupla; k es el índice de los elementos de la tupla.

Distancia euclidiana: Es la raíz cuadrada de la sumatoria de las diferencias entre los elementos de las tuplas al cuadrado, Ecuación 3.25

$$d(i, j) = (\sum_{k=1}^m |x_{ik} - x_{jk}|^2)^{\frac{1}{2}} \quad (3.25)$$

donde: x es la tupla de 2 filas para el cálculo de la distancia entre sus filas; para el cálculo de la distancia entre sus filas; (i, j) son m es la dimensión de la tupla; k es el índice de los elementos de la tupla.

Distancia de ajedrez: La distancia es el valor más alto de las diferencias absolutas de los elementos, Ecuación 3.26 [Chatzichristofis, 2011].

$$d(i, j) = \max\{|x_{i1} - x_{j1}|, |x_{i2} - x_{j2}|, \dots, |x_{im} - x_{jm}|\} \quad (3.26)$$

donde: x es la tupla de 2 filas para el cálculo de la distancia entre sus filas; para el cálculo de la distancia entre sus filas; (i, j) son m es la dimensión de la tupla; k es el índice de los elementos de la tupla. max es la función de encontrar al máximo de las tuplas.

Distancia Canberra: Similar a la distancia Manhattan, Ecuación 3.27, la diferencia es que es dividida por la suma de absoluta de sus valores [Bloom, 1981].

$$d(i, j) = \sum_{k=1}^m \frac{|x_{ik} - x_{jk}|}{(|x_{ik}| + |x_{jk}|)} \quad (3.27)$$

donde: x es la tupla de 2 filas para el cálculo de la distancia entre sus filas; para el cálculo de la distancia entre sus filas; (i,j) son m es la dimensión de la tupla; k es el índice de los elementos de la tupla.

Distancia Mahalanobis: Similar a la euclidiana (Ecuación 3.28) en que esta medida toma en cuenta la correlación de los datos, es decir, la matriz de covarianza es usada como factor en las diferencias de ambas tuplas, además de que ese invariante a la escala de dichas tuplas de muestras.

$$M_{ij} = r^2(x_i, x_j) = (x_i - m'_j)^T C^{-1} (x_i - m'_j) \quad (3.28)$$

donde; T es la transpuesta de la tupla de características x ; C^{-1} es la inversa de la covarianza de las dos tuplas; m' es la media de los valores de la tupla de características respectivas.

Distancia Tanimoto: Es la razón entre dos tuplas de características, obteniendo como salida un valor entre cero y uno (Ecuación 3.29) [Tanimoto, 1982] .

$$T_{ij} = t(x_i, x_j) = \frac{x_i^T x_j}{x_i^T x_i + x_j^T x_j - x_i^T x_j} \quad (3.29)$$

donde; T es la transpuesta de la tupla de características x ; C^{-1} es la inversa de la covarianza de las dos tuplas; m es la media de los valores de la tupla de características respectivas.

Error Absoluto: Es la suma de las distancias que existe entre dos vectores de la misma magnitud. (Ecuación 3.30).

$$r = \sum_n |(g_p[n] - g_q[n])| \quad (3.30)$$

donde: $g_p[n]$, representa la secuencia de la entropía estándar (es la salida de la serie de tiempo), de la imagen p ; $g_q[n]$, representa la secuencia de la entropía estándar (es la salida de la serie de tiempo), de la imagen q .

Medida Johnson: Johnson propone usar el vector normalizado usando las características en cada tiempo. De esta forma se obtiene la información de similitud entre dos objetos, cuando dos objetos son el mismo J es 1, Ecuación 3.31 [Fei, 2008].

$$J = 1.0 - \sum_n |(g_p[n] - g_q[n])| \quad (3.31)$$

donde: $g_p[n]$, representa la secuencia de la entropía estándar (es la salida de la serie de tiempo), de la imagen p ; $g_q[n]$, representa la secuencia de la entropía estándar (es la salida de la serie de tiempo), de la imagen q .

Distancia S: Es una medida de similitud, similar a la medición de Canberra y Johnson. Toma en cuenta los cuadrados y el resultado es la suma de la distancia entre las dos series, multiplicado

por cien. De esta forma se obtiene la información de similitud entre dos objetos, cuando dos series de tiempo son iguales S es igual a 100, en caso contrario a 0 (Ecuación 3.32).

$$S = \left(1.0 - \frac{\sum_n |(g_p[n] - g_q[n])|^2}{\sum_n (g_p[n]^2 + g_q[n]^2)} \right) * 100 \quad (3.32)$$

donde: $g_p[n]$, representa la secuencia de la entropía estándar (es la salida de la serie de tiempo), de la imagen p ; $g_q[n]$, representa la secuencia de la entropía estándar (es la salida de la serie de tiempo), de la imagen q .

3.8 Discusión

En el presente capítulo se describieron conocimientos de un proceso de implementación de los paradigmas pulso acoplados para extraer características de una imagen digital, se describe la hipótesis de la invariancia de la “Firma” obtenida a partir de una imagen con distintos grados de transformación de rotación, escalado, ruido aditivo e impulsivo. De la “Firma” principal (serie de tiempo) se derivan ocho formas distintas de obtener una “Firma” para finalmente elegir una.

También se describen los conceptos involucrados en la aplicación de medidas de similitud entre “Firmas” dadas por una RNP. Con base en la información presentada en este capítulo se determina lo siguiente:

- La similitud entre dos “Firmas” se basa en una operación donde los valores numéricos de los vectores n -ésimos son comparados uno a uno, es decir se busca una mayor aproximación entre un vector y otro, para garantizar la calidad de la “Firma” aun con invariantes de rotación, escalado y ruido.
- La métrica S seleccionada expresa sus valores de 0 a 100, siendo 0 el menor número de semejanza, y 100 para el mayor número de semejanza entre las “Firmas”.
- La “Firma” obtenida de una imagen es invariante a la “Firma” obtenida dada una transformación a la imagen ya sea de rotación, escalado, ruido aditivo y ruido impulsivo.

Capítulo IV

Análisis, Diseño e Implementación

En este capítulo se da a conocer el proceso de análisis, diseño e implementación del paradigma neuronal pulso acoplado, incluyendo el material y las tecnologías empleadas para la extracción de características de una imagen digital, así también es necesaria la comparación entre las “Firmas” de las imágenes, por lo que se describe el proceso para obtener la similitud y la medida empleada. En la sección de extracción de características se describen 8 distintas formas básicas de obtener una “Firma”, y una forma de obtener una “Firma” propuesta en esta tesis.

4.1 Análisis y Diseño

Se pretende analizar la creación de un sistema computacional para la obtención de “Firmas” de una imagen digital. El objetivo del análisis es cumplir a través de los procesos y etapas en base a los requerimientos necesarios para su desarrollo, para ello, en el análisis se incluirá de forma general las imágenes, los paradigmas pulsantes y a partir del paradigma neuronal pulsante, se determinará el diseño general para generar “Firmas” de imágenes digitales, para finalmente implementar un algoritmo pulsante que obtenga 9 “Firmas” distintas por cada imagen. Para complementar se analizarán las ”Firmas” obtenidas de las imágenes originales y sus respectivas transformaciones de escalado, rotación, ruido impulsivo y ruido aditivo, por medio de una medida de similitud propuesta en esta tesis. La Figura 4.1 muestra los requerimientos y como se relacionan entre sí, esto para desarrollar la arquitectura del proceso y la implementación del paradigma neuronal pulso acoplado.

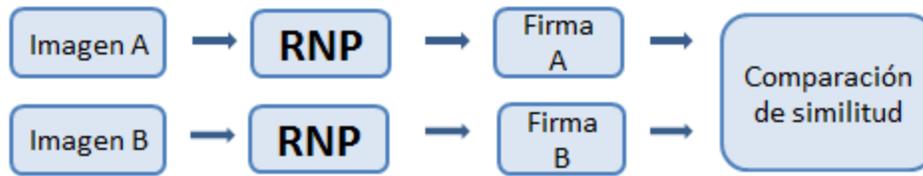


Figura 4.1 Análisis de problema

La figura 4.1 muestra las principales fases del problema a resolver. Primeramente la obtención de las imágenes de entrada es importante, ya que hay que determinar el formato, tipo de imagen digital, bytes, resolución, tipo de color o tamaño; posteriormente hay que determinar qué tipos y cuántos algoritmos neuronales pulsantes se pueden implementar para las imágenes de entrada; una vez determinado el tipo de imágenes y el algoritmo, se iniciará la experimentación para la obtención de distintos tipos de “Firmas”; finalmente con una medida de similitud se compararán las “Firmas” para determinar las ventajas y desventajas que tiene este paradigma pulsante de tercera generación.

La figura 4.2 muestra el diagrama general que se realizó para obtener todas las “Firmas” de las imágenes originales e imágenes transformadas (Rotación, Escalado, Ruido), posteriormente hacer una comparación entre las “Firmas” obtenidas con una medida de similitud.

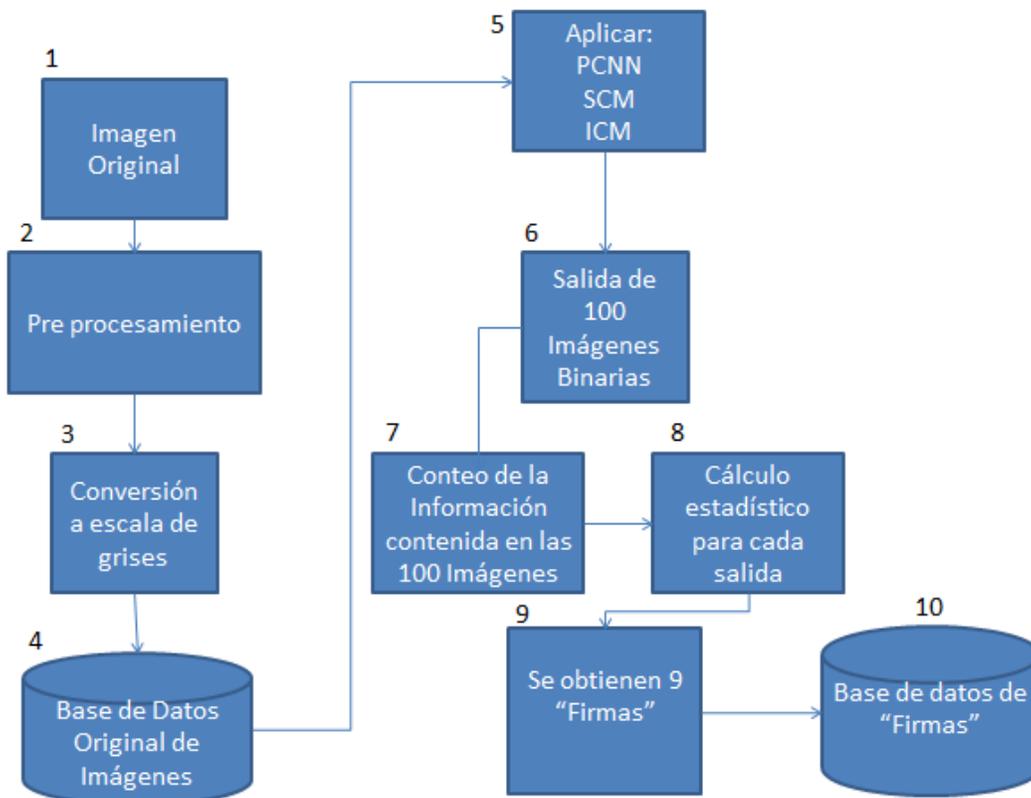


Figura 4.2 Diagrama general para la obtención de firmas

Los pasos descritos en la Figura 4.2 se describen a continuación:

1.- Se obtiene la imagen a color original; primeramente son descargadas imágenes de la web, particularmente imágenes ya tratadas por distintos autores tales como Lena, Cameraman, etc, posteriormente se escoge una base de imágenes del CENIDET, que contiene 30 imágenes de 3 tipos: montañas, flores y pasto (ver Figura 4.3).



Figura 4.3 Ejemplo de tres tipos de imágenes

2.- La imagen nuevamente guardada con la ayuda de *Paint*; una vez obtenida la imagen es estandarizada, es decir con ayuda de *Paint* la imagen se estandarizada en tamaño (128x128 pixeles) y formato (JPG) para todas las imágenes (ver Figura 4.4).



Figura 4.4 Ejemplo del pre-procesamiento de las imágenes originales de entrada

3.- Se obtiene la imagen en escala de grises con ayuda de las librerías de OpenCV; con ayuda de las librerías de OpenCv las imágenes a color estandarizadas (Paso anterior) son procesadas para obtener una nueva imagen en escala de grises (ver Figura 4.5).



Figura 4.5 Ejemplo del pre-procesamiento de las imágenes de entrada en escala de grises

4.- Se guarda la imagen en una base de datos para su procesamiento posterior; La nueva imagen en escala de grises se guarda en una base de datos temporal, ya que esta es la imagen final es decir la imagen de entrada para los algoritmos PCNN, ICM y SCM (ver Figura 4.6)



Figura 4.6 Ejemplo de imágenes de entrada a la Red Neuronal Pulsante, finalmente es la imagen de entrada

5.- Se hace uso de uno de los paradigmas de RNP; la imagen en escala de grises es la entrada de la red. Si una RNP es alimentada, esta producirá una salida y se autoalimentara, por lo tanto necesita de una condición de paro, ya que la red puede autoalimentarse hasta que ceda la memoria o la energía de la computadora y como el tiempo de procesamiento no es de interés tanto que en la literatura no existe tal condición la imagen es procesada con 100 iteraciones por cada algoritmo (ver Figura 4.7).



Figura 4.7 Ejemplo de entrada a los Paradigmas pulso acoplados

6.- Se obtienen las imágenes binarias como salida de las RNPs; por cada iteración que los algoritmos crean una imagen binaria, esta imagen es guardada momentáneamente para ser examinada por el algoritmo, es decir se obtienen 100 imágenes binarias por cada imagen de entrada (ver Figura 4.8).

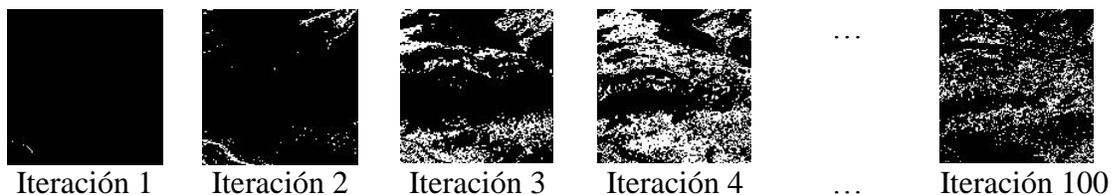


Figura 4.8 Ejemplo de la salida de las RNPs como imágenes binarias

7.- Se obtiene el número de 1's y de 0's de cada una de las imágenes binarias obtenidas; por medio de una función el algoritmo obtiene el número de pixeles prendidos por cada imagen binaria obtenida del paso anterior (ver Figura 4.9).

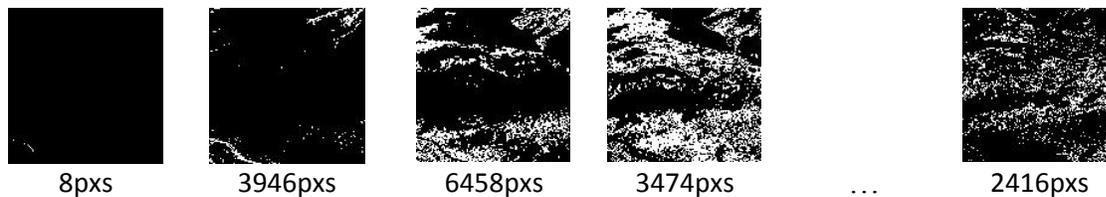


Figura 4.9 Ejemplo del conteo de pixeles encendidos en cada imagen binaria

8.- El conteo de la salida de la RNP es transformado para extraer 9 formas de “Firmas” distintas; La Figura 4.9 muestra el conteo de cada imagen binaria en total se utilizan 9 funciones distintas para obtener 9 “Firmas” distintas por cada imagen de entrada (ver Figura 4.10).

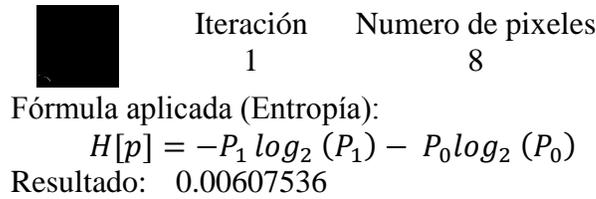


Figura 4.10 Ejemplo de la aplicación de la Entropía para los valores numéricos de los pixeles encendidos

9.- Se grafica en 2 ejes la firma, el eje x para el tiempo, es decir para el número n de imagen, el eje y para el número de 1’s de la imagen n; la gráfica obtenida de este paso es llamada la “Firma” de la imagen original. Se presentan los datos de las imágenes binarias como un solo vector de 100 elementos “Firma” (ver Figura 4.11).

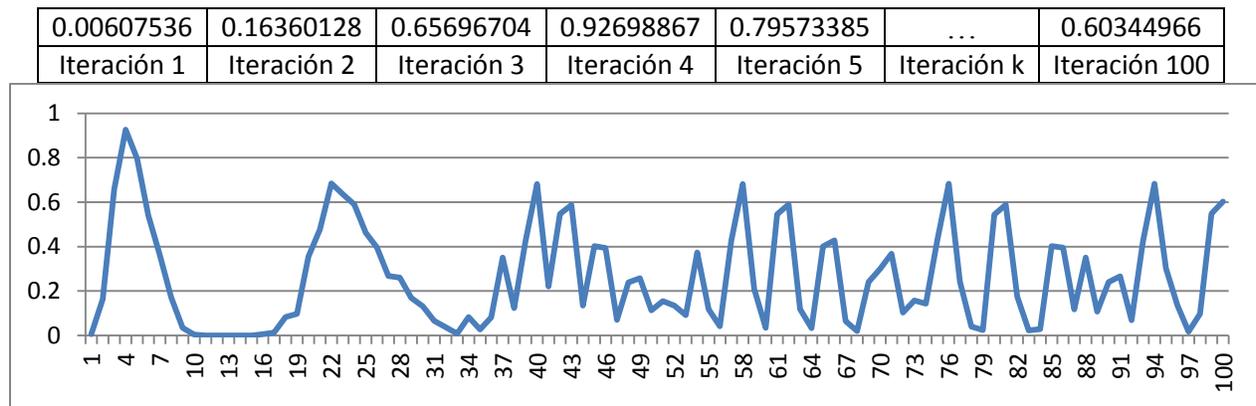


Figura 4.11 Ejemplo de la obtención de una “Firma” en base a la fórmula de Entropía

10.- Las 9 “Firmas” son guardadas para poder ser comparadas con una medida de similitud; las “Firmas” se guardan en un documento .xml, los datos son guardados en forma de un vector (“Firma”), es decir se guardan 100 números o datos, obtenidos de las iteraciones del algoritmo por cada imagen de entrada (ver Figura 4.12).

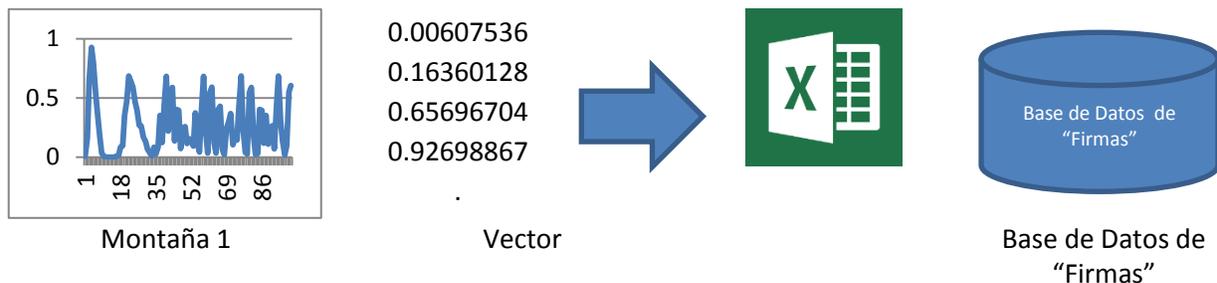


Figura 4.12 Ejemplo de una “Firma” guardada como un vector n-esimo en formato .XML

Una vez obtenida la base de imágenes sin transformaciones se procede a obtener la base de datos de las “Firmas” para cada una de las imágenes, el objetivo principal es tomar una imagen de la base de imágenes y que tal imagen sufra una transformación ya sea de escalamiento, rotación o ruido, para posteriormente tomar su “Firma” de la imagen transformada y poder ser comparada con la base de datos de las “Firmas” existente, entonces con una medida de similitud determinar si existe una “Firma” parecida en la base de datos de “Firmas”. Es posible derivar nuevas series a partir de la serie de tiempo (Ecuaciones 3.24 - 3.32), las ecuaciones fueron implementadas dentro del algoritmo, tomando como salida la imagen binaria, de esta forma es posible tomar 9 “Firmas” distintas por cada imagen (ver Figura 4.13).

4.1.1 Obtención de una “Firma” de una Imagen

Esta sección introducirá la aplicación de las RNPs en el campo de reconocimiento de patrones, especialmente extrayendo características en base a las RNPs. Posteriormente introduciremos otras medidas estadísticas para medir la eficiencia en las series de tiempo.

Johnson construyó un tipo de transformada que una suma para cada salida binaria de la imagen de la PCNN es una serie en una dimensión, la llamó serie de tiempo $G[n]$ (Ecuación 3.14)

La RNP genera imágenes binarias como salida, dependiendo del número de iteraciones. Para cada iteración se cuentan el número de 1’s y 0’s de cada imagen binaria.

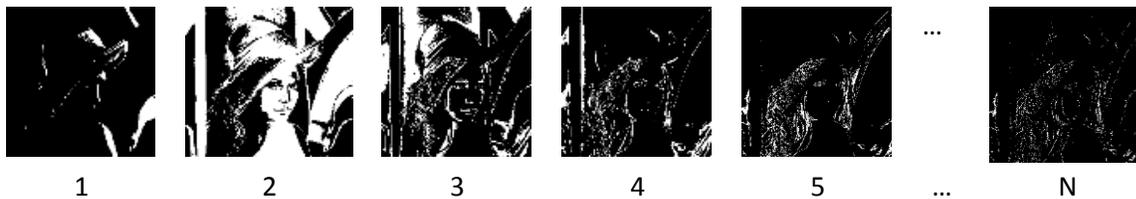
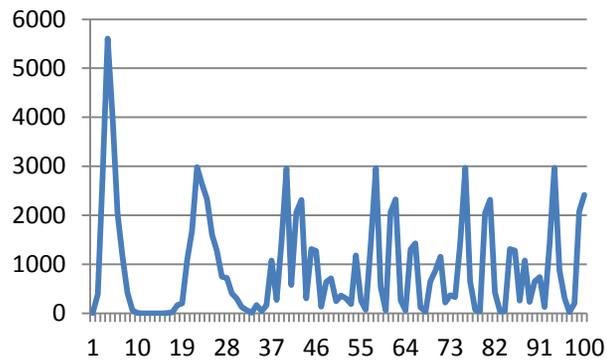


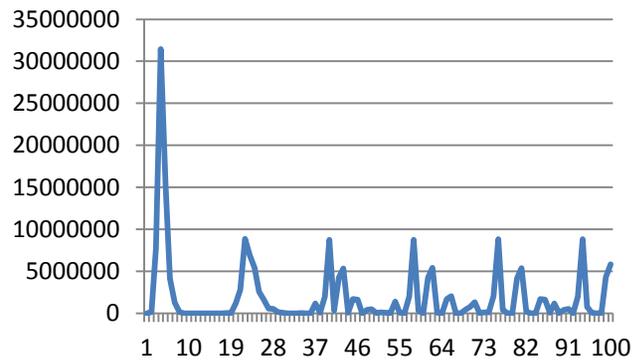
Figura 4.14 Ejemplo de imágenes binarias creadas por una RNP

La Figura 4.14(1) de Lena, es la primera salida de la primera iteración de la RNP, la Figura 4.14(2) corresponde a la segunda imagen binaria (segunda iteración), así sucesivamente, de esta forma se toman en cuenta los píxeles prendidos de cada imagen formando un vector de tamaño n y de forma numérica o una “Firma” o serie de tiempo de forma gráfica (ver Figura 4.15).

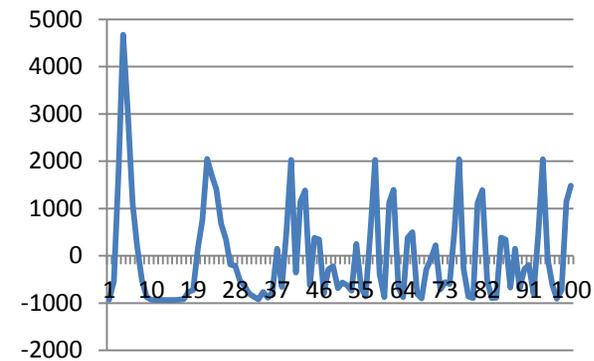
De la Ecuación 3.11 se obtienen el número de 1’s y 0’s de la imagen binaria resultante para cada iteración de la RNP, es decir, se obtiene un vector del tamaño n del número de iteraciones, como lo indica la Figura 4.15. Se toman los valores de las iteraciones mapeados en una gráfica y se obtiene una “Firma” con la Ecuación 3.14 (ver Figura 4.16).



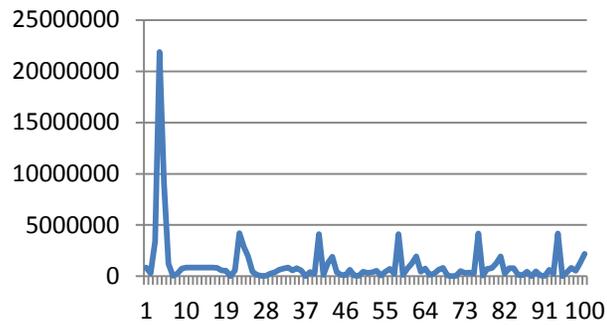
Serie de tiempo (Ecuación 3.11)



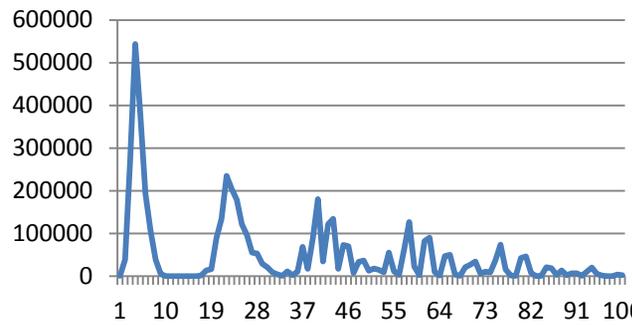
Serie de Energía de tiempo (Ecuación 3.12)



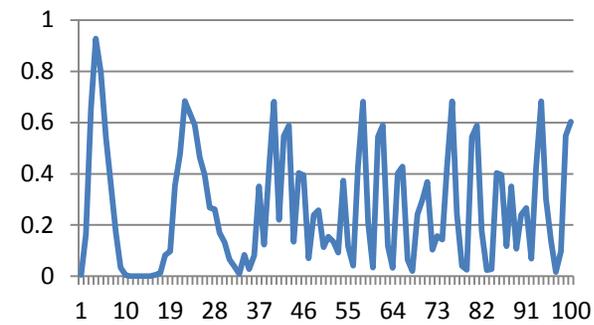
Media residual (Ecuación 3.13)



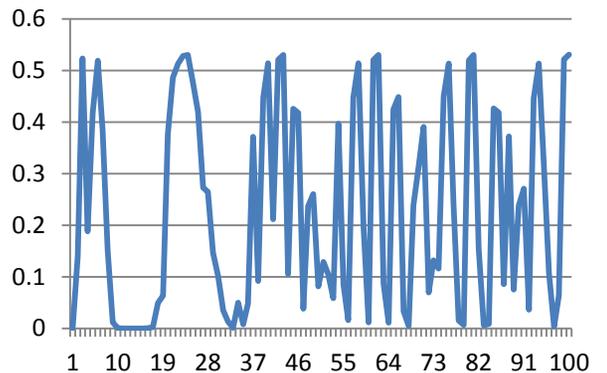
Desviación estándar (Ecuación 3.14)



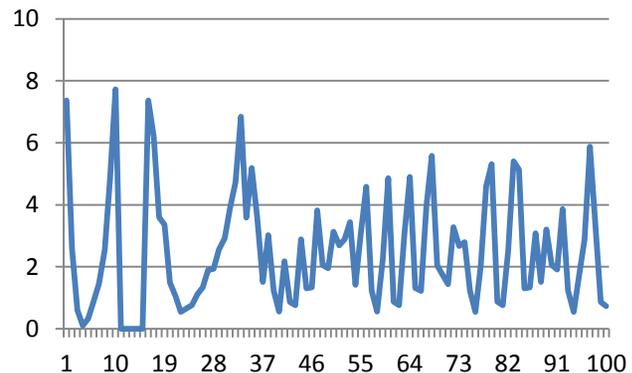
Serie Ponderada (Propuesta) (Ecuación 3.15)



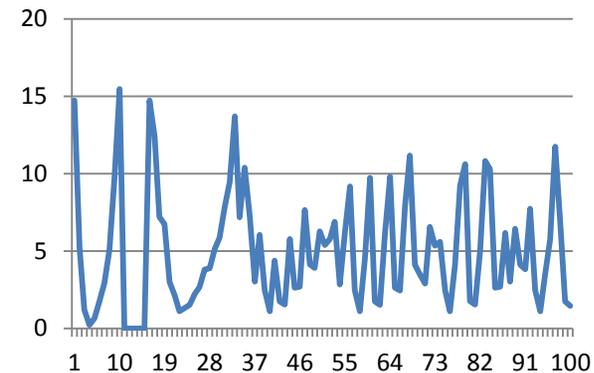
Entropía (Ecuación 3.16)



Energía logarítmica (Ecuación 3.17)



Logarítmica (Ecuación 3.18)



Energía entrópica (Ecuación 3.19)

Figura 4.13 Ejemplo de 9 “Firmas” distintas para la imagen de Montaña1

							
# 1's	4026	8137	4026	1566	618	412	0
Iteración	G1	G2	G3	G4	G5	G6	G7

Figura 4.15 Salida de imágenes binarias de una RNP

En la sección 3.5 se describieron las ecuaciones con las cuales se obtuvieron las distintas series de tiempo o “firmas” (Ecuaciones 3.24 - 3.32). Que una vez que se ha obtenido $G[n]$, es aplicada cada una de las Ecuaciones 3.25 – 3.32 y son obtenidas 9 “Firmas” que pueden ser representadas con 9 vectores.

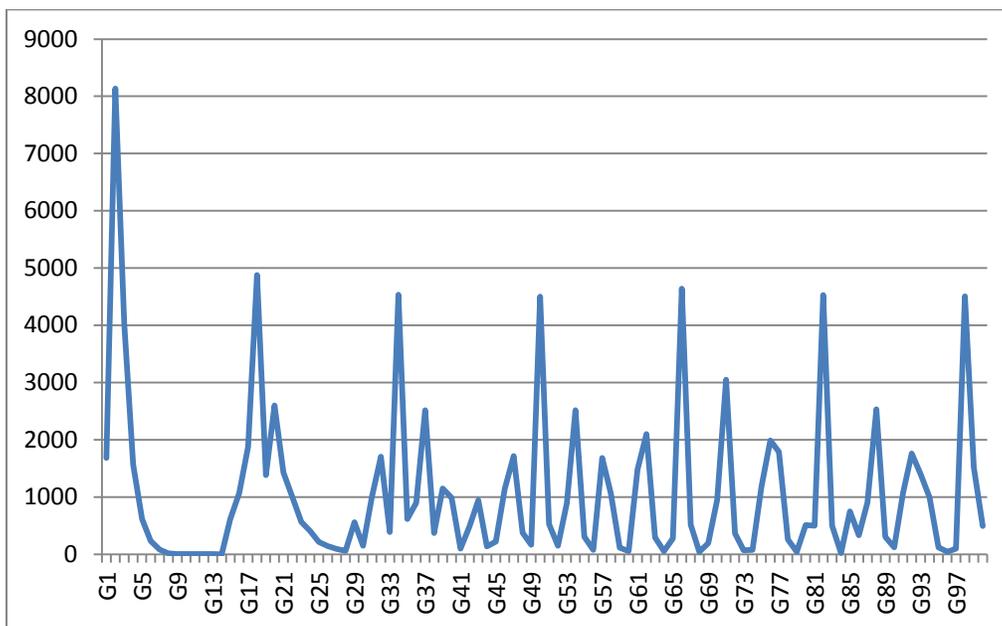


Figura 4.16 Ejemplo de una firma de una imagen

4.1.2 Similitud entre imágenes

Una vez obtenidas las “Firmas” de las imágenes, es necesario obtener una medida de similitud entre las “Firmas” o series de tiempo de las imágenes, esto para poder medir qué tanto las “Firmas” son parecidas y para llevar a cabo esta similitud se hace uso de la Ecuación 3.32

La Tabla 4.1 muestra un ejemplo de la obtención del grado de similitud entre dos “Firmas”, aplicando la Ecuación 3.32, así se puede observar que el grado de similitud sólo entre dos imágenes.

Tabla 4.1 Ejemplo para obtener la similitud entre “Firmas” o series de tiempo

$g_p[n]$	$g_q[n]$	$g_p[n]^2$	$g_q[n]^2$	$g_p[n]^2 + g_q[n]^2$	$(g_p[n] - g_q[n])^2$	
8	0	64	0	64	64	
394	317	155236	100489	255725	5929	
2780	2815	7728400	7924225	15652625	1225	
5608	5791	31449664	33535681	64985345	33489	
3939	3982	15515721	15856324	31372045	1849	
2033	1941	4133089	3767481	7900570	8464	
1136	1097	1290496	1203409	2493905	1521	
422	397	178084	157609	335693	625	
58	36	3364	1296	4660	484	
6	6	36	36	72	0	
0	0	0	0	0	0	
0	2	0	4	4	4	
				123000708	53654	
						$(1.0 - \frac{\sum_n (g_p[n] - g_q[n]) ^2}{\sum_n (g_p[n]^2 + g_q[n]^2)}) * 100$
						99.956379

El diagrama de la Figura 4.17 muestra las transformaciones hechas a la base de imágenes original (Color), en rotación, escala y ruido para cada imagen, tales imágenes resultantes formarán parte de la Base de Imágenes de entrada de las RNPs, esto para extraer las características por medio de una “Firma” o “Firmas” extraídas con los 9 métodos antes descritos. Finalmente las “Firmas” extraídas de las nuevas imágenes ya transformadas se compararán con la Base de “Firmas” obtenida anteriormente de las 30 imágenes originales a color (es decir sin ningún tipo de transformación), para analizar si las “Firmas” extraídas corresponden o tienen el mejor grado de similitud con su imagen original, es decir si la ”Firma” obtenida de la imagen rotada, escalada o con ruido genera una “Firma” parecida a la “Firma” de la imagen original o si es que existe una diferencia notable con la “Firma” de la imagen transformada.

4.2 Implementación de los modelos pulsantes

La RNP es una red que contiene dos compartimientos principales *Feeding* (*F*) y *Linking* (*L*) donde éstos se comunican con sus neuronas vecinas a través de los pesos sinápticos *M* y *W*. Cada uno de ellos retiene su estado previo pero con un factor de decaimiento. Sólo el *Feeding* recibe un estímulo de entrada *S*. El estado de estos dos compartimientos es combinado en un segundo orden, para crear un estado interno *U* de la neurona. El estado interno de la neurona es comparado con un umbral dinámico *E* y produce una salida *Y* (ver Figura 4.18).

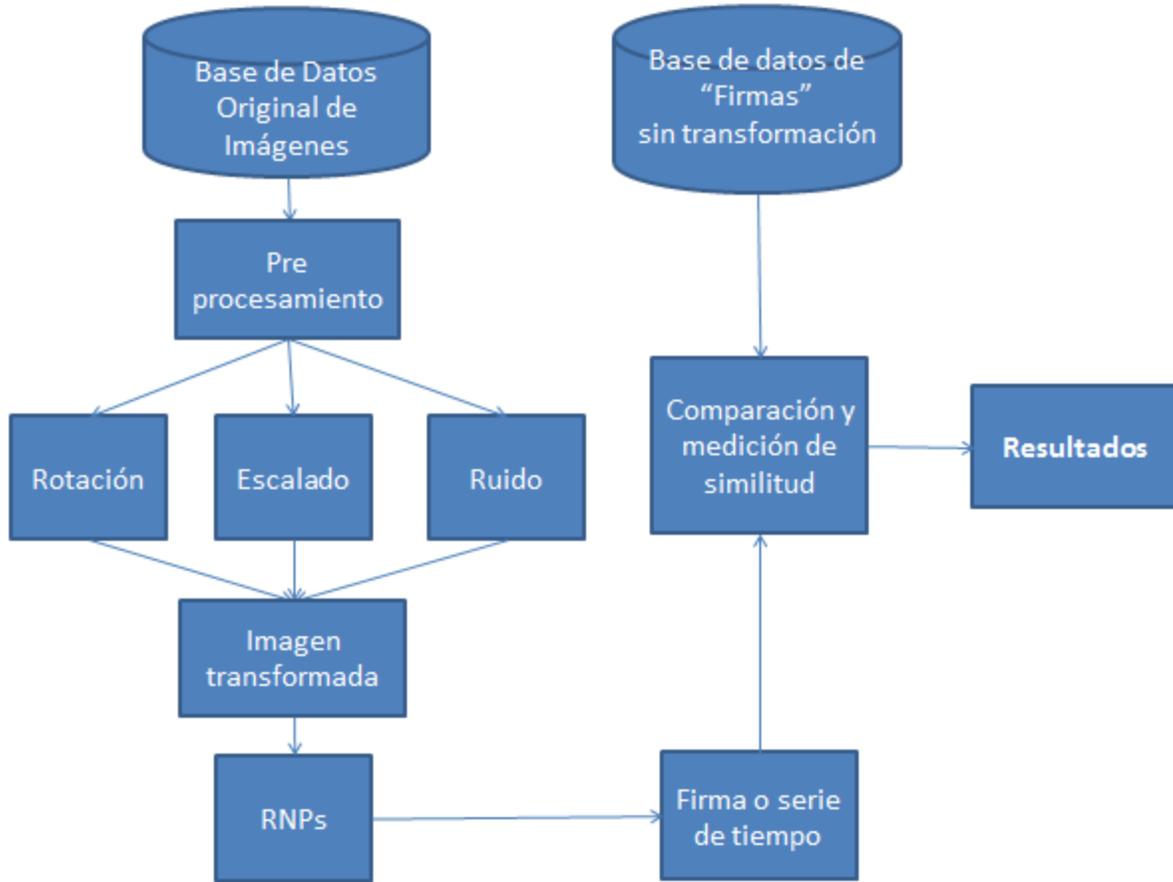


Figura 4.17 Diagrama de las Imágenes invariantes de comparación de "firmas" medición del grado de similitud

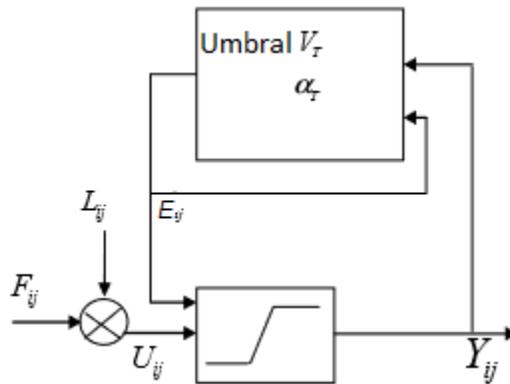


Figura 4.18 Modelo simple de una RNP [Ma, 2010]

El modelo matemático para los tres paradigmas fue presentado en la sección anterior. El diseño de la implementación de éstos es la siguiente:

4.2.1 Modelo Computacional PCNN

Como lo muestra la Figura 4.19, [Lindblad, 2005] la neurona de una PCNN, acepta como entrada el *Feeding* (F) y al *Linking* (L) y entonces genera actividad interna U . Cuando U es mayor que el umbral dinámico E , la PCNN produce un pulso secuencial Y .

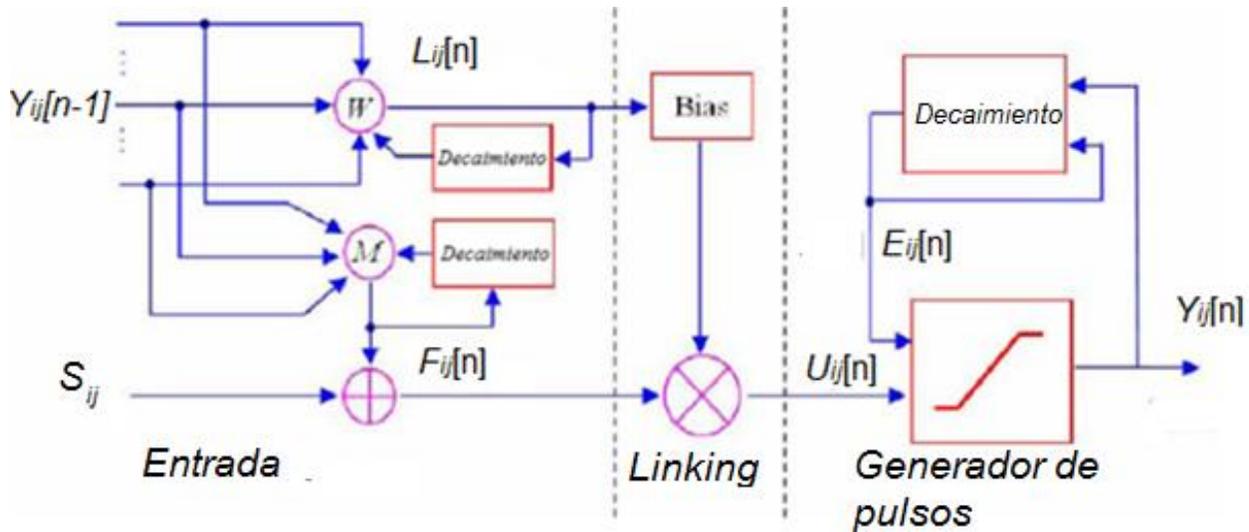


Figura 4.19 Modelo de una red neuronal pulsante PCNN

El Algoritmo, muestra el funcionamiento computacional de las Ecuaciones (3.3 - 3.7), como parámetros se le asignó lo siguiente: el algoritmo tiene como entrada dos variables enteras *filas*, *columns*, donde *filas* corresponde al número de pixeles horizontales de la imagen de entrada (S), *columns* es el número de pixeles verticales de la imagen de entrada (S), contiene 8 constantes ($n, V_F, V_L, V_E, Beta, Alpha_F, Alpha_L, Alpha_E$) n es número de iteraciones de la RNP o el número de paro, $V_F, V_L, V_E, Beta, Alpha_F, Alpha_L, Alpha_E$ son valores de ajuste y decaimiento ya determinados por los parámetros de entrada, también como entrada tiene 9 matrices ($S, F, L, U, E, Y, Convolucion, M, W$), M y W son matrices inicializadas de 3×3 y F, L, U, E, Y son variables inicializadas según los parámetros de entrada (regularmente a 0 o 1), las variables $S, F, L, U, E, Y, Convolucion$ son matrices de tamaño k, l (donde k es el número de filas y l el número de columnas de la imagen original). La variable *Convolucion* es la matriz que representa la sumatoria del producto escalar de M, W y Y , es decir $\sum_{kl} M_{ijkl} Y_{kl}[n - 1]$, $\sum_{kl} W_{ijkl} Y_{kl}[n - 1]$ de la Ecuación 3.1 y 3.2, que se interpreta como la convolución de una imagen, en este caso la convolución de Y con M y W . Como en este caso M y W son iguales la variable *Convolucion* contiene el mismo valor en $\sum_{kl} M_{ijkl} Y_{kl}[n - 1]$, $\sum_{kl} W_{ijkl} Y_{kl}[n - 1]$. S es la única entrada como una imagen en escala de grises. La función *Unos()*, es un contador del número de bits (1's) asignados a Y o la imagen binaria. La matriz Y representa la imagen binaria obtenida en la iteración c .

Function PCNN
ENTRADA: <i>filas, columnas, n: entero; S,F,L,U,E,Y,Convolucion: matrices;</i>
INICIALIZA: $V_F \leftarrow 0.8, V_L \leftarrow 0.2, V_E \leftarrow 20, \text{Beta} \leftarrow 0.1, \text{Alpha}_F \leftarrow 0.1,$ $\text{Alpha}_L \leftarrow 1.0, \text{Alpha}_E \leftarrow 1.0$
<pre> 1 For c := 0 to n //n es el número de iteraciones 2 For i := 0 to filas 3 For j := 0 to columnas 4 F[j][i] = exp(-Alpha_F) * F[j][i] + V_F * Convolucion[j][i] + S[j][i]; 5 L[j][i] = exp(-Alpha_L) * L[j][i] + V_L * Convolucion[j][i]; 6 U[j][i] = F[j][i]*(1+Beta*L[j][i]); 7 E[j][i] = exp(-Alpha_E) * T[j][i] + V_E* Y[j][i]; 8 if (U[j][i] > E[j][i]){ 9 Y[j][i]= 1; 10 Unos(); //función cuenta los pixeles prendidos 11 } 12 else 13 Y[j][i]= 0; 14 End for j 15 End for i 16 End for c </pre>
SALIDA: Y es la nueva imagen binaria obtenida

4.2.2 Modelo Computacional ICM

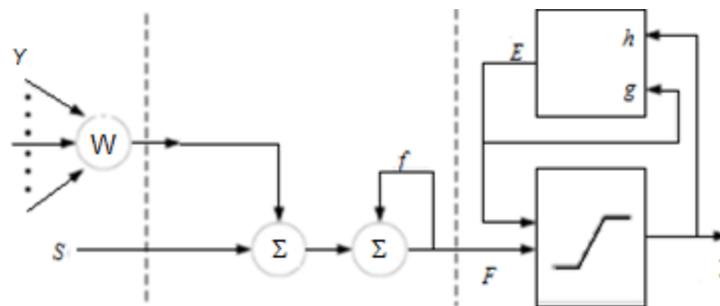


Figura 4.20 Modelo de una red neuronal pulsante ICM

La Figura 4.20 muestra el modelo de ICM. El Algoritmo, muestra el funcionamiento computacional de las Ecuaciones 3.8 - 3.10, como parámetros se le asignó lo siguiente; el algoritmo tiene como entrada dos variables enteras *filas*, *columnas*, donde *filas* corresponde al número de píxeles horizontales de la imagen de entrada (S), *columnas* es el número de píxeles verticales de la imagen de entrada (S); contiene cuatro constantes (n, f, g, h) n es número de iteraciones de la RNP; f, g, h son constantes de ajuste y tiene como entrada seis matrices ($M, S, F, T, Y, Convolucion$), M es una matriz inicializada de 3×3 , F, T, Y son inicializadas según los parámetros de entrada (regularmente a 0 o 1), la variable *Convolucion* es una matriz de tamaño k, l (donde k es el número de filas y l el número de columnas de la imagen original) que representa la sumatoria del producto escalar de M y Y , o sea $\sum_{kl} M_{ijkl} Y_{kl}[n-1]$ de la Ecuación

3.8, que se puede interpretar como la convolución de una imagen, en este caso la convolución de Y y M . S es la única entrada de la imagen en escala a grises.

Function ICM	
ENTRADA: $filas, columnas, n$: entero; $S, F, E, Y, Convolucion$: matrices;	
INICIALIZA: $f \leftarrow 0.1, g \leftarrow 0.9, H \leftarrow 20$,	
1	For c := 0 to n //n es el número de iteraciones
2	For i := 0 to filas
3	For j := 0 to columnas
4	$F[j][i] = f * F[j][i] + Convolucion[j][i] + S[j][i];$
5	$E[j][i] = g * E[j][i] + H * Y[j][i];$
6	if ($F[j][i] > E[j][i]$) {
7	$Y[j][i] = 1;$
8	Unos(); //función cuenta los pixeles prendidos
9	}
10	Else
11	$Y[j][i] = 0;$
12	End for j
13	End for i
14	End for c
SALIDA: Y es la nueva imagen binaria obtenida	

4.2.3 Modelo Computacional SCM

El algoritmo, muestra el funcionamiento computacional de las ecuaciones (3.11 - 3.13), como parámetros se le asignó lo siguiente; el algoritmo tiene como entrada dos variables enteras $filas, columnas$, donde $filas$ corresponde al número de pixeles horizontales de la imagen de entrada (S), $columnas$ es el número de pixeles verticales de la imagen de entrada (S), contiene cinco constantes (γ, n, f, g, h) n es número de iteraciones de la RNP o el número de paro f, g, h son constantes de ajuste, el algoritmo también tiene como entrada seis matrices ($S, F, T, Y, Convolucion, W$), W es una matriz de 3×3 y F, T, Y son inicializadas según los parámetros de entrada (regularmente a 0 o 1), las variables $F, T, Y, Convolucion$ son matrices de tamaño k, j (donde k es el número de filas y l el número de columnas de la imagen original) $Convolucion$ es una matriz que representa la sumatoria del producto escalar de M y Y , es decir $\sum_{kl} M_{ijkl} Y_{kl} [n - 1]$ de la Ecuación 3.6, que se interpreta computacionalmente como la convolución de una imagen, en este caso la convolución de Y y M . S es la única entrada como una imagen en escala a grises. La función $Unos()$, es un contador del número de bits (1's) asignados a Y o la imagen binaria. La matriz Y representa la imagen binaria obtenida en la iteración c . A diferencia de los Algoritmos de PCNN y ICM, la salida generada como pulsos es producida por una función sigmoideal, llamada $sigmoide()$ donde γ es una constante. Modelo SCM ver Figura 4.22

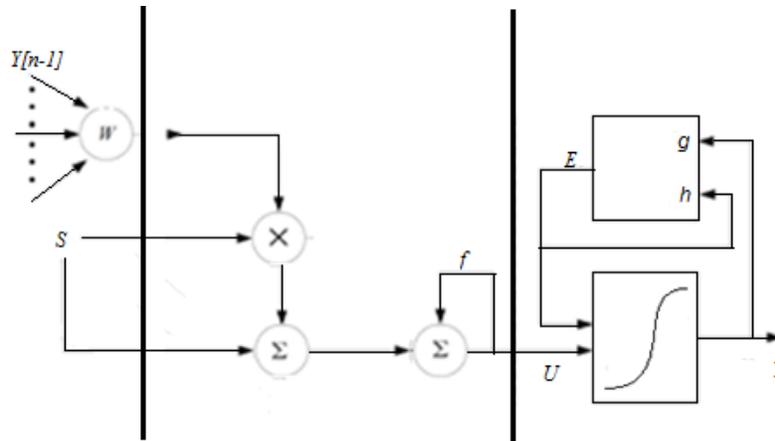


Figura 4.22 Modelo de una red neuronal pulsante SCM

Function SCM	
ENTRADA: <i>filas, columnas, n</i> : entero; <i>S,U,E,Y,Convolucion</i> : matrices;	
INICIALIZA: $f \leftarrow 0.1, g \leftarrow 0.9, H \leftarrow 20,$	
1	For c := 0 to n //n es el número de iteraciones
2	For i := 0 to filas
3	For j := 0 to columnas
4	$U[j][i] = f * U[j][i] + (S[j][i] * Convolucion[j][i]) + S[j][i];$
5	$E[j][i] = g * E[j][i] + h * Y[j][i];$
6	if (sigmoide($U[j][i], E[j][i]$) > 0.5){ //function sigmoideal
7	$Y[j][i] = 1;$
8	Unos(); //función cuenta los pixeles prendidos
9	}
10	else
11	$Y[j][i] = 0;$
12	End for j
13	End for i
14	End for c
SALIDA: Y es la nueva imagen binaria obtenida	

4.3 Implementación de las nueve “Firmas”

La Figura 4.23 muestra cómo se obtienen los vectores que representaran las 9 “Firmas” distintas entre imágenes transformadas, en la figura se puede observar la obtención de las 8 firmas subsecuentes de la serie de tiempo $G[n]$ (En total 9 “Firmas”). Como ya se ha mencionado antes, la imagen es procesada por una RNP, la cual obtiene su “Firma” por medio del conteo de 1’s de las imágenes binarias salientes, posteriormente los valores obtenidos por medio de $G[n]$ de la Ecuación 3.11 son guardados en un vector de tamaño 100 (Figura 4.23 sólo muestra algunos valores), los 100 valores del vector de $G[n]$ son sustituidos como valores de x ,

para las Ecuaciones 3.12 -3.19. Obteniendo sistemáticamente cada uno de los valores para los ocho nuevos vectores.

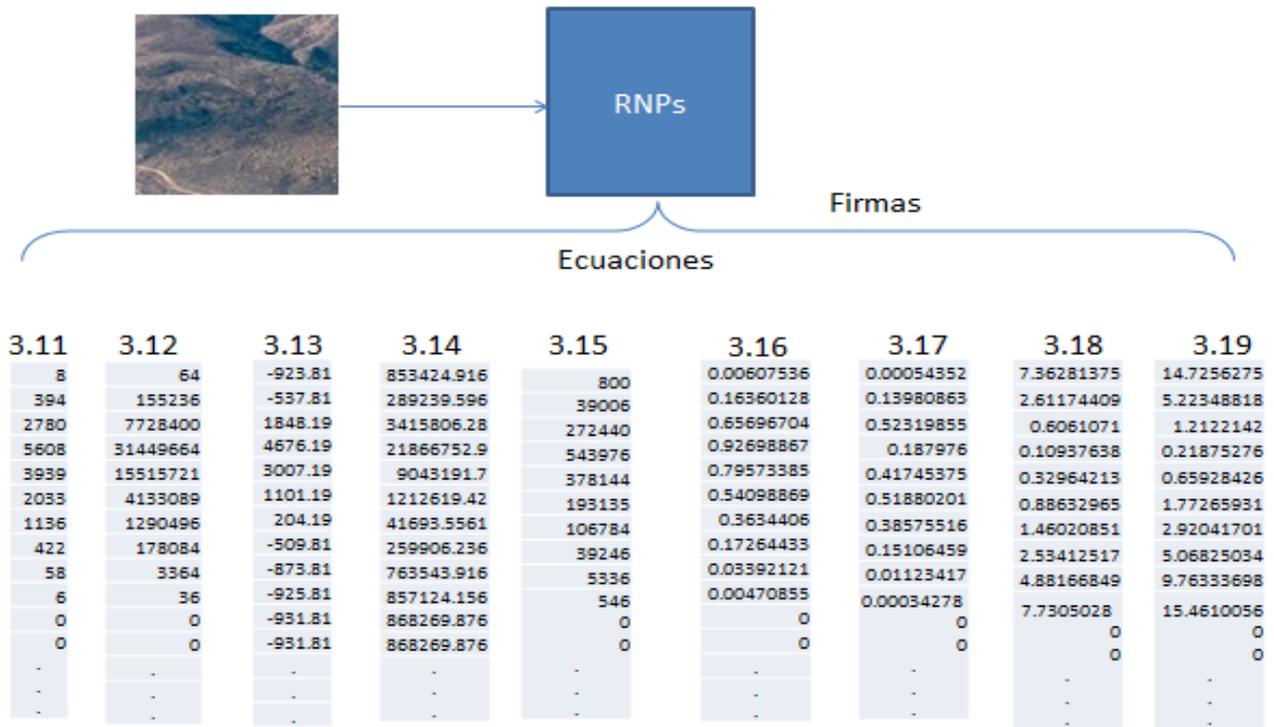


Figura 4.23 Ejemplo de la obtención de los nueve vectores que representan una “Firma” de una imagen

Los nueve valores son guardados en un archivo, para su posterior comparación de similitud entre valor y valor de cada “Firma” de otras imágenes.

La Figura 4.24 muestra un diagrama del funcionamiento de la función *Unos()* que aparecen en los algoritmos anteriores. La función *Unos()* es inicializada en 0. Una vez que una imagen es tratada con la RNP, esta genera una imagen binaria, la función *Unos()* contiene un contador que suma el número de 1’s que existen en la imagen binaria *n*, ya que el algoritmo tiene una condición de paro en la iteración 100, verifica si la iteración es menor que 100, si la opción es no, la función toma el valor de *cont* (numero de 1’s que existen en la imagen binaria) para su iteración *n* y toma como *x* el valor de *cont*, para las funciones *e1,e2,e3,e4*. Para obtener los valores de *H[p]*, *e5,e6,e7*, primero se obtiene el complemento de *x(cont)* y posteriormente se aplican las ecuaciones, para finalmente ir guardando en un archivo de texto los valores para cada vector.

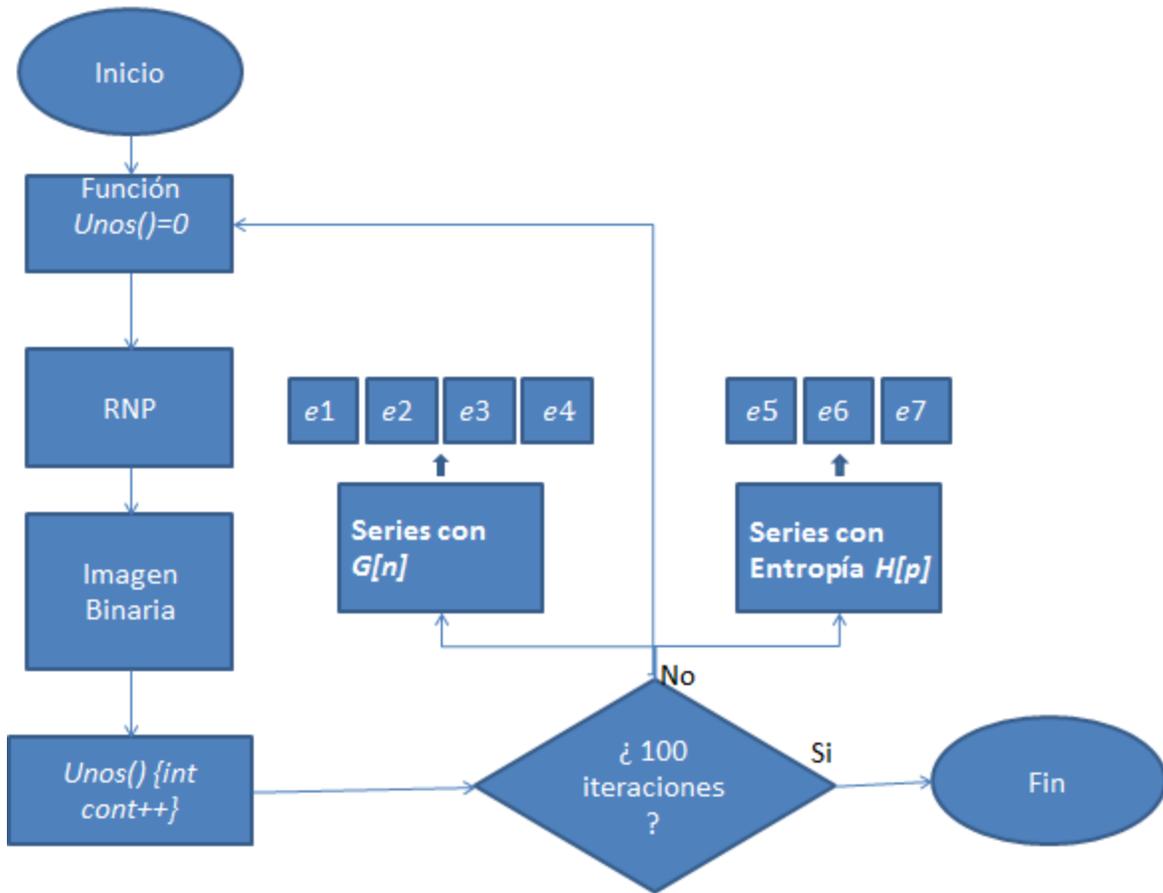


Figura 4.24 Diagrama de flujo de la función *Unos()*

4.4 Implementación de la similitud de las “Firmas”

Una vez implementadas las RNPs, para todas las imágenes de prueba, es necesario medir la calidad de las “Firmas” obtenidas con las tres variantes de RNPs y sus respectivas nueve “Firmas”. Dados los datos obtenidos se midió la similitud de la “Firma” con distintas medidas de similitud capítulo 3.7, a diferencia de todas las medidas la medida de similitud, la que se tomó en cuenta es (*S*) Ecuación 3.32, donde los valores pueden ser leídos en un rango de 0 para “Firmas” totalmente distintas o 100 para “Firmas” iguales, lo que proporciona que los resultados pueden ser leídos con mayor facilidad que los datos arrojados con otras mediciones.

Tabla 4.2 Comparación de similitud entre imágenes

Similitud	Escala	Rotación	Ruido	Otras imagen
PCNN	Sí	Sí	No	Sí
ICM	Sí	Sí	No	Sí
SCM	Sí	Sí	Sí	Sí

La Tabla 4.2 muestra las comparaciones realizadas de las “Firmas” obtenidas, es decir se obtuvieron “Firmas” con PCNN fueron comparadas con (S) Ecuación 3.32, para los casos de escala, rotación, ruido y entre imágenes de diferente tipo. Para los casos de PCNN e ICM no se realizaron comparaciones de “Firmas” dados los resultados de la sección 5.

Para realizar la comparación de la similitud entre las “Firmas” se creó una hoja de cálculo en Excel, donde las “Firmas” fueron ordenadas por imagen, se creó una hoja de cálculo por cada imagen original, su respectivo paradigma y su transformación, es decir existe una hoja de cálculo por cada una de las 30 imágenes y cada hoja de cálculo contiene el cálculo de (S) Ecuación 3.32, de las “Firmas” comparadas. Al aplicar la ecuación (S) se obtendrá un número cercano a 100 para indicar que la “Firma” de la imagen es muy parecida a la “Firma” original y se obtendrá un número cercano a 0 para indicar que la imagen es muy distinta a la original, finalmente en forma de resumen se obtendrán otras tablas de síntesis para deducir qué “Firma” tiene un mejor comportamiento en general.

4.5 Discusión

El presente capítulo describió el análisis, diseño e implementación de los paradigmas pulso acoplados PCNN, ICM y SCM para la extracción de características de una imagen digital, por medio de una “Firma” o serie de tiempo. Cada uno de los procesos está descrito de acuerdo a las etapas de los diagramas mostrados para lograr el objetivo de esta tesis. El análisis y el diseño determinaron los elementos que intervienen para la solución del problema, también se describió la implementación de los algoritmos pulsantes (PCNN, ICM, SCM); que prácticamente contiene 2 etapas: La extracción de características por obtención de “Firmas” aplicando una RNP y la evaluación de la calidad de las “Firmas” obtenidas contra “Firmas” obtenidas de las transformaciones aplicadas a las imágenes digitales, tales como rotación, escalado y ruido, esto para determinar si las “Firmas” siguen siendo invariantes considerando sus respectivas transformaciones.

Los tres algoritmos están implementados bajo programación C++, cada implementación es individual. Con el desarrollo de los algoritmos, no sólo se dispone de una nueva herramienta para continuar experimentando dentro de las redes neuronales pulsantes, sino también brinda la posibilidad de extraer otras características tales como media de escala en grises, media para cada canal RGB, desviación estándar para cada canal u otras características como momentos de Hu , esto para ayudar a la RNP a contener mejor información de la imagen.

Capítulo V

Experimentación y Resultados

Este capítulo presenta los experimentos realizados una vez obtenida la base de imágenes completa, se presentan los resultados de dichos experimentos para la extracción de características de una imagen digital con los paradigmas pulsantes PCNN, ICM y SCM. Los casos de prueba son de rotación, escalado, ruido aditivo y ruido impulsivo. La serie de tiempo es tomada para transformarla en nueve formas distintas de obtener una “firma” con las ecuaciones presentadas en el capítulo III; finalmente se presentan resultados de la evaluación de las “firmas” obtenidas con una medida de similitud.

5.1 Experimentación

En la siguiente sección se muestran los resultados obtenidos de la experimentación de acuerdo al proceso general. Se hace una contribución experimental de los paradigmas pulsantes PCNN, ICM, y SCM para describir características de imágenes digitales y así como obtener la mejor salida a partir de 9 formas distintas de analizar la firma. Primeramente de las 30 imágenes principales (Montañas, Flores, Pasto), con 100 iteraciones se obtuvieron 9 firmas para cada una de las imágenes, y sus respectivas transformaciones de cada una de las imágenes.

5.1.1 Tecnologías empleadas:

Esta sección describe el material y las tecnologías empleadas. Los paradigmas neuronales PCNN, ICM y SCM se desarrollaron bajo las siguientes características:

5.1.1.1 Hardware

- Computadora Sony Vaio (VPCEL)
 - **Procesador:** AMD E-350 Processor 1.60 Ghz
 - **RAM:** 3.60 GB RAM
 - **SO:** Sistema 64 bits
Windows 7 Enterprise. 2009

5.1.1.2 Software

- Eclipse IDE for C/C++ Developers/Version: Kepler Service Release 2
- MinGW Command Prompt TDM GCC 64 bits
- Librería OpenCV 2.4.8
- Microsoft Windows Paint versión 6.1 (compilación 7600)

5.1.2 Base de datos de imágenes

Para la generación de la base de imágenes se utilizaron dos colecciones de imágenes; por una parte está constituida por imágenes de bases de datos del CENIDET [Pérez, 2015] e imágenes de una base de datos de la red [Corbis corporation, 2002] con un total de 30 imágenes de tamaño de 128x128 píxeles; de las 30 imágenes, 10 son de montañas, 10 de flores y 10 de pasto (ver Figuras 5.1 - 5.3, respectivamente).

Montañas (tipo I)



Montaña1



Montaña2



Montaña3



Montaña4



Montaña5



Montaña6



Montaña7



Montaña8



Montaña9



Montaña10

Figura 5.1 Imágenes de distintos tipos de montañas. (Tipo 1)

Flores (tipo II)



Figura 5.2 Imágenes de distintos tipos de flores (Tipo 2)

Pasto (tipo III)



Figura 5.3 Imágenes de distintos tipos de pasto (Tipo 3)

La Figura 5.4 muestra un ejemplo de los resultados obtenidos de acuerdo al proceso general, a partir de la “Firma” original de cada imagen, se obtendrán las 9 firmas para cada una de las imágenes con los paradigmas pulsantes PCNN, ICM y SCM.

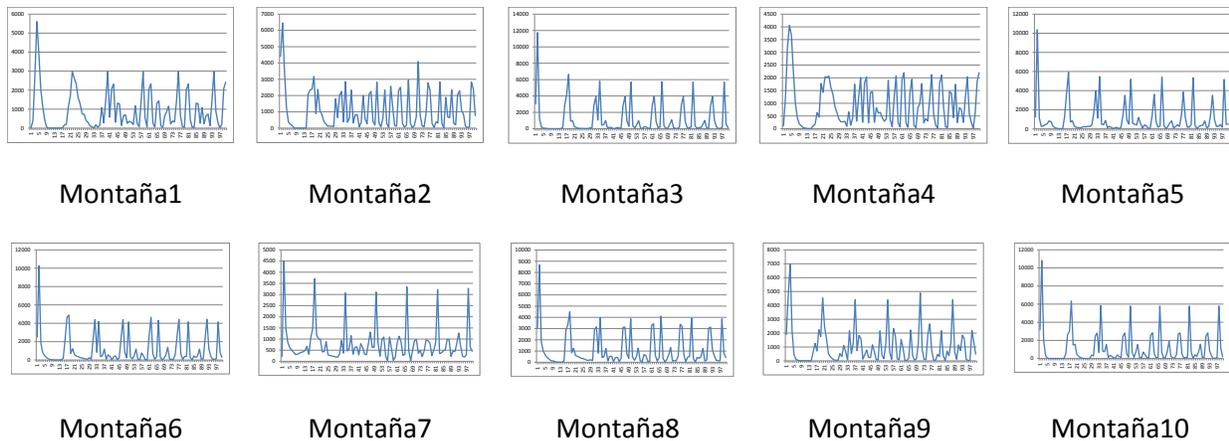


Figura 5.4 Ejemplo de firmas obtenidas con SCM para los casos de montaña

5.1.3 Plan de pruebas

Se detalla el plan de pruebas en 5 fases de desarrollo.

5.1.3.1 Fase 1

- Se desarrollaron los paradigmas neuronales PCNN, ICM y SCM.
- Se escogen 30 imágenes de 128 x 128 píxeles (10 Montañas, 10 Flores, 10 Pasto).
- Se aplica PCNN, ICM, SCM a las 30 imágenes (90 firmas).
- Se calculan las 9 series (810 firmas).

5.1.3.2 Fase 2

- Cada imagen es transformada en 20 rotaciones (600 imágenes).
- Se aplica PCNN, ICM, SCM a las 600 imágenes (1,800 firmas).
- Se calculan las 9 series (16,200 firmas).

5.1.3.3 Fase 3

- Cada imagen es transformada en 10 escalas (300 imágenes).
- Se aplica PCNN, ICM, SCM a las 300 imágenes (900 firmas).
- Se calculan las 9 series (8,100 firmas).

5.1.3.4 Fase 4

- Cada imagen es transformada en 6 imágenes con dos tipos de ruido (360 imágenes).
- Se aplica PCNN, ICM, SCM a las 360 imágenes (1,080 firmas).

- Se calculan las 9 series (9,720 firmas).

5.1.3.5 Fase 5

Evaluación con la métrica S seleccionada y análisis:

- Evaluaciones con rotación ($420 \times 10 \times 3$) = 12,600 evaluaciones.
- Evaluaciones con escalado ($110 \times 10 \times 3$) = 3,300 evaluaciones.
- Evaluaciones entre Montañas y Flores, Flores y Pasto, Montañas y Pasto.
- Evaluaciones con características básicas de una imagen.

5.2 Resultados

Esta sección muestra los resultados de la experimentación realizada a la base de imágenes completa y los distintos casos de transformación, como los casos de rotación, casos de escalamiento, casos con ruido aditivo y casos con ruido impulsivo.

5.2.1 Casos Rotación

Para obtener la base de imágenes total, para la transformación de rotación, fue tomada una imagen, fue rotada y cortada por el centro, con un tamaño de 128x128 pixeles con un formato JPG, Figura 5.5, para la estandarización del tamaño de la imagen.

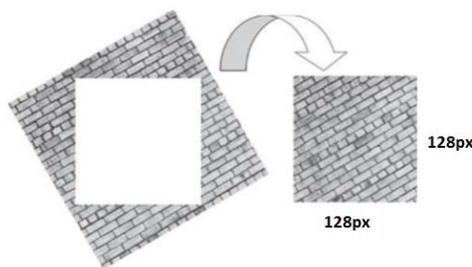


Figura 5.5 Imagen rotada para estandarizar el tamaño de la imagen

Cada imagen (Figuras 5.1 – 5.3) fue rotada en los siguientes grados: 1° , 2° , 3° , 4° , 5° , 6° , 7° , 8° , 9° , 10° , 20° , 30° , 40° , 50° , 60° , 70° , 80° , 90° , 180° y 270° , agregando 20 imágenes (Figura 5.6), obteniendo 600 imágenes transformadas; a cada imagen se le aplicó los paradigmas PCNN, ICM y SCM. De las 600 “Firmas” obtenidas de las imágenes, se calcularon 9 series de tiempo, obteniendo un total de 16,200 “Firmas” o series de tiempo.

Las siguientes gráficas de barras muestran las similitudes (S) (Ecuación 3.32) de la firma o serie de tiempo hechas con la Ecuación 3.14 ($G[n]$) de la imagen original, comparada con sus respectivas rotaciones para cada una de las redes pulsantes PCNN, ICM, SCM, (a, b, c respectivamente ver Figura 5.7).



Figura 5.6 Ejemplo de rotación de una imagen

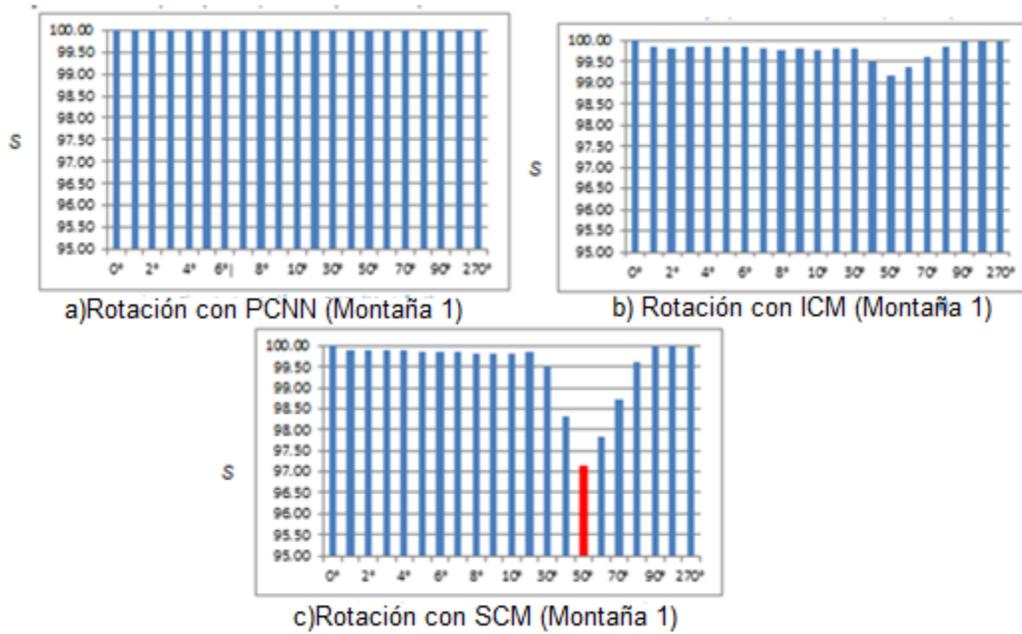


Figura 5.7 Gráficas ejemplo para el caso de rotación de las “Firmas” de Motana1 con PCNN, ICM y SCM con $G[n]$

La Tabla 5.1 muestra los resultados obtenidos con la Ecuación 3.32, al medir la comparación entre la imagen original para las nueve series de tiempo (Tablas completas en CD).

Tabla 5.1 Ejemplo de una tabla de similitud entre todas las imágenes transformadas de Montaña ICM con $G[n]$

Imágenes rotadas	0°	1°	2°	3°	4°	5°	6°	7°	8°	9°	10°	20°	30°	40°	50°	60°	70°	80°	90°	180°	270°	Promedio
0°	100	99.94	99.93	99.94	99.94	99.91	99.9	99.91	99.87	99.87	99.87	99.9	99.74	99.21	98.69	98.97	99.4	99.81	99.99	100	99.99	99.75
1°	99.94	100	99.98	99.97	99.98	99.98	99.96	99.97	99.95	99.94	99.94	99.89	99.5	98.87	98.3	98.64	99.23	99.72	99.89	99.92	99.89	99.69
2°	99.93	99.98	100	99.98	99.99	99.97	99.99	99.96	99.97	99.96	99.96	99.92	99.48	98.84	98.27	98.59	99.18	99.67	99.89	99.91	99.89	99.68
3°	99.94	99.97	99.98	100	99.99	99.98	99.98	99.97	99.96	99.97	99.95	99.9	99.47	98.82	98.23	98.57	99.14	99.66	99.91	99.92	99.91	99.68
4°	99.94	99.98	99.99	99.99	100	99.98	99.97	99.99	99.98	99.97	99.97	99.94	99.47	98.8	98.21	98.54	99.11	99.65	99.91	99.92	99.91	99.68
5°	99.91	99.98	99.97	99.98	99.98	100	99.95	99.98	99.97	99.95	99.95	99.88	99.4	98.69	98.09	98.45	99.06	99.62	99.87	99.9	99.87	99.64
6°	99.9	99.96	99.99	99.98	99.97	99.95	100	99.96	99.96	99.97	99.96	99.91	99.39	98.71	98.1	98.43	99.04	99.59	99.86	99.88	99.86	99.64
7°	99.91	99.97	99.96	99.97	99.99	99.98	99.96	100	99.97	99.97	99.98	99.92	99.4	98.66	98.05	98.41	98.99	99.58	99.88	99.9	99.88	99.63
8°	99.87	99.95	99.97	99.96	99.98	99.97	99.96	99.97	100	99.98	99.98	99.93	99.35	98.62	98.03	98.35	98.95	99.53	99.85	99.86	99.85	99.61
9°	99.87	99.94	99.96	99.96	99.97	99.95	99.97	99.97	99.98	100	99.99	99.95	99.34	98.62	97.99	98.3	98.9	99.49	99.85	99.85	99.84	99.6
10°	99.87	99.94	99.96	99.95	99.97	99.95	99.96	99.98	99.98	99.99	100	99.96	99.34	98.59	97.97	98.29	98.88	99.48	99.85	99.86	99.85	99.6
20°	99.9	99.89	99.9	99.47	98.82	98.23	98.57	99.14	99.93	99.95	99.96	100	99.52	98.87	98.29	98.53	99	99.52	99.89	99.88	99.89	99.39
30°	99.74	99.5	99.48	99.47	99.47	99.4	99.39	99.4	99.35	99.34	99.52	99.82	100	99.82	99.54	99.68	99.75	99.82	99.75	99.75	99.75	99.61
40°	99.21	98.87	98.84	98.82	98.8	98.69	98.71	98.66	98.62	98.62	98.59	98.87	99.82	100	99.9	99.91	99.8	99.56	99.21	99.21	99.21	99.14
50°	98.69	98.3	98.27	98.23	98.21	98.09	98.1	98.05	98.03	97.99	97.97	98.29	99.54	99.9	100	99.93	99.67	99.23	98.69	98.69	98.69	98.69
60°	98.57	98.59	98.59	98.59	98.59	98.59	98.59	98.59	98.59	98.59	98.59	98.57	98.53	98.52	98.51	100	98.56	98.57	98.56	98.57	98.56	98.64
70°	99.4	99.23	99.11	99.06	99.04	100	98.9	99.23	98.95	98.9	98.88	99	99.75	99.8	99.67	99.83	100	99.85	99.34	99.39	99.34	99.37
80°	99.81	99.72	99.65	99.62	99.59	99.58	99.49	99.72	99.53	99.49	99.48	99.52	99.82	99.56	99.23	99.5	99.85	100	100	99.8	99.76	99.65
90°	99.99	99.89	99.91	99.87	99.86	99.88	99.85	99.89	99.85	99.85	99.85	99.89	99.75	99.21	98.69	98.95	99.34	99.76	100	99.99	100	99.73
180°	100	99.92	99.92	99.9	99.88	99.9	99.85	99.92	99.86	99.85	99.86	99.88	99.75	99.21	98.69	98.98	99.39	99.8	99.99	100	99.99	99.74
270°	99.99	99.89	99.89	99.91	99.91	99.87	99.86	99.88	99.85	99.84	99.85	99.89	99.75	99.21	98.69	98.95	99.34	99.76	100	99.99	100	99.73
																						99.52

La Tabla 5.1 muestra la similitud que existe entre la imagen original y sus transformadas, solo para el caso de rotación de una sola imagen, de uno de los paradigmas; al tomar en consideración que son demasiados datos, se mostrarán sólo como ejemplo el contenido de algunas de las tablas obtenidas y tablas que de manera de resumen generen un panorama general del comportamiento de las redes neuronales pulsantes, todas las tablas completas están contenidas en un archivo .Xml en CD ya que son muchos los datos a tomar en cuenta (9 tablas por imagen, 90 tablas por tipo de imagen, 810 tablas por paradigma, 2,430 tablas en total); se consideró tomar un promedio para cada una de las nueve series de cada imagen, es decir las nueve tablas obtenidas por cada imagen son resumidas en una tabla resumen como lo indica la Figura 5.8.

Las Tabla 5.2, 5.3 y 5.4 se obtuvieron como lo indica la Figura 5.8, la figura muestra las tablas obtenidas para cada serie, es decir la Tabla 5.1 muestra la similitud sólo la serie de tiempo $G[n]$, se considera la columna de promedios para formar una nueva tabla resumen junto con las ocho tablas restantes (otras series). Así al comparar todas imágenes originales (color) con sus transformaciones en rotación, disminuirá el número de los datos en las tablas, es decir en total son 90 tablas (30 por cada imagen y tres paradigmas PCNN, ICM, SCM), con las 30 tablas de un sólo paradigma, una tabla muestra 10 promedios de las 10 imágenes de un solo tipo (Montaña, Flores o Pasto), así se obtienen tres tablas con datos más sencillos de leer y los resultados puedan ser mejor descritos.

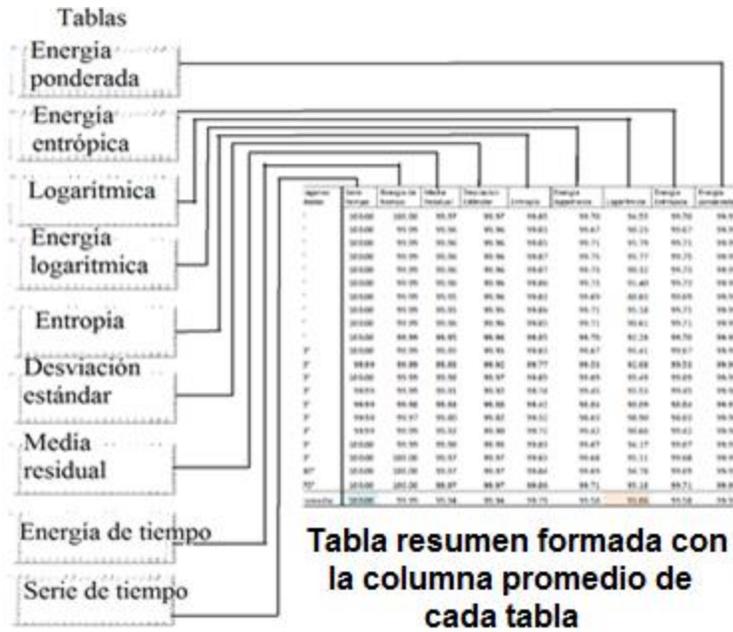


Figura 5.8 Ejemplo de la obtención de las tablas promedio para cada imagen

Tabla 5.2 Ejemplo de comparación de similitud entre rotación Series PCNN (Montaña 1)

Imágenes rotadas	Serie tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
0°	100.00	100.00	99.97	99.97	99.82	99.50	90.15	90.15	99.99
1°	100.00	99.99	99.97	99.97	99.81	99.44	90.70	90.70	99.99
2°	100.00	99.99	99.97	99.97	99.83	99.53	91.17	91.17	99.99
3°	100.00	99.99	99.97	99.97	99.84	99.55	95.08	95.08	99.99
4°	100.00	99.99	99.97	99.96	99.82	99.46	90.68	90.68	99.99
5°	100.00	99.99	99.96	99.96	99.83	99.48	91.35	91.35	99.99
6°	100.00	99.99	99.96	99.96	99.80	99.43	96.02	96.02	99.99
7°	100.00	99.99	99.96	99.96	99.80	99.39	92.30	92.30	99.99
8°	100.00	99.99	99.96	99.96	99.83	99.49	95.86	95.86	99.99
9°	100.00	99.99	99.96	99.96	99.82	99.46	95.84	95.84	99.99
10°	100.00	99.99	99.96	99.96	99.78	99.37	96.04	96.04	99.99
20°	99.99	99.99	99.94	99.94	99.71	99.14	96.97	96.97	99.99
30°	100.00	99.99	99.97	99.97	99.82	99.47	95.53	95.53	99.99
40°	99.99	99.99	99.92	99.92	99.67	98.99	95.73	95.73	99.98
50°	99.99	99.98	99.87	99.88	99.43	98.29	95.62	95.62	99.97
60°	99.98	99.98	99.86	99.85	99.28	98.01	77.25	77.25	99.96
70°	99.99	99.99	99.93	99.91	99.58	98.74	96.23	96.25	99.98
80°	100.00	99.99	99.97	99.96	99.78	99.35	96.26	96.26	99.99
90°	100.00	99.99	99.97	99.97	99.73	99.26	95.04	95.04	99.99
180°	100.00	100.00	99.97	99.97	99.80	99.44	89.89	89.89	99.99
270°	100.00	100.00	99.97	99.97	99.80	99.39	92.30	92.30	99.99
Promedio de similitud	99.99	99.99	99.95	99.95	99.74	99.25	93.14	93.14	99.99

Tabla 5.3 Ejemplo rotación Series ICM (Montaña 1)

Imágenes rotadas	Serie tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
0°	99.78	98.83	98.59	96.20	99.93	99.80	36.73	99.80	99.60
1°	99.77	98.57	98.44	95.05	99.95	99.84	50.97	99.84	99.56
2°	99.76	98.53	98.37	95.05	99.95	99.83	58.40	99.83	99.56
3°	99.76	98.51	98.40	94.95	99.95	99.84	50.74	99.84	99.57
4°	99.75	98.42	98.35	94.44	99.95	99.83	38.73	99.83	99.53
5°	99.75	98.35	98.31	94.25	99.96	99.83	52.98	99.83	99.52
6°	99.75	98.36	98.35	94.17	99.99	99.97	54.76	99.97	99.97
7°	99.73	98.23	98.15	93.81	99.95	99.83	58.59	99.83	99.48
8°	99.70	98.06	97.97	93.32	99.95	99.80	63.78	99.80	99.44
9°	99.71	98.10	98.05	93.41	99.95	99.82	65.03	99.82	99.45
10°	99.69	98.03	97.90	93.40	99.94	99.79	38.08	99.79	99.43
20°	99.75	98.52	98.35	95.05	99.95	99.84	56.47	99.84	99.54
30°	99.73	98.30	98.16	94.15	99.95	99.81	55.08	99.81	99.53
40°	99.46	96.16	96.28	86.14	99.91	99.65	12.58	99.65	98.98
50°	99.20	94.36	94.60	80.05	99.87	99.50	-2.28	99.50	98.45
60°	99.36	95.44	95.75	83.36	99.88	99.56	-12.22	99.56	98.58
70°	99.58	97.09	97.28	89.11	99.92	99.72	61.89	99.72	99.11
80°	99.77	98.59	98.50	94.95	99.95	99.83	71.10	99.83	99.53
90°	99.70	98.71	98.06	96.29	99.91	99.73	62.98	99.73	99.49
180°	99.76	98.85	98.44	96.44	99.93	99.78	63.47	99.78	99.58
270°	99.71	98.74	98.11	96.37	99.96	99.84	69.32	99.84	99.51
Promedio de similitud	99.67	97.94	97.83	92.85	99.94	99.78	47.96	99.78	99.40

La Tabla 5.5 muestra un ejemplo de las tres tablas resumen resultantes en este caso es sólo para el de tipo montaña, la tabla está compuesta de diez filas, cada fila corresponde a uno de los promedios de las diez imágenes de montaña, entonces las filas son sacadas como datos de algunas de las tablas anteriores (Tablas completas en CD), en las columnas se observan cada una de las nueve series de tiempo o “Firmas” propuestas en esta tesis para cada imagen y en la última fila, se muestra también un promedio para las 10 imágenes del mismo tipo, esto para tener un resultado aún más general de las diferencias entre las “Firmas” resultantes del mismo tipo.

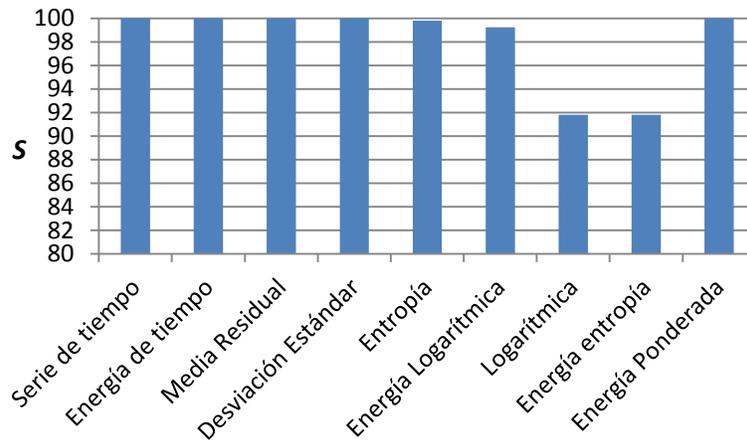
La Figura 5.9 muestra una gráfica de barras que resumen las tres tablas que surgen una red neuronal pulsante sólo para el caso invariante a la rotación. Es decir la gráfica muestra de forma general el resumen para los 3 tipos de imágenes, esto es un panorama muy general para todas las imágenes probadas con invariancia a distintos grados de rotación.

Tabla 5.4 Ejemplo rotación con Series SCM

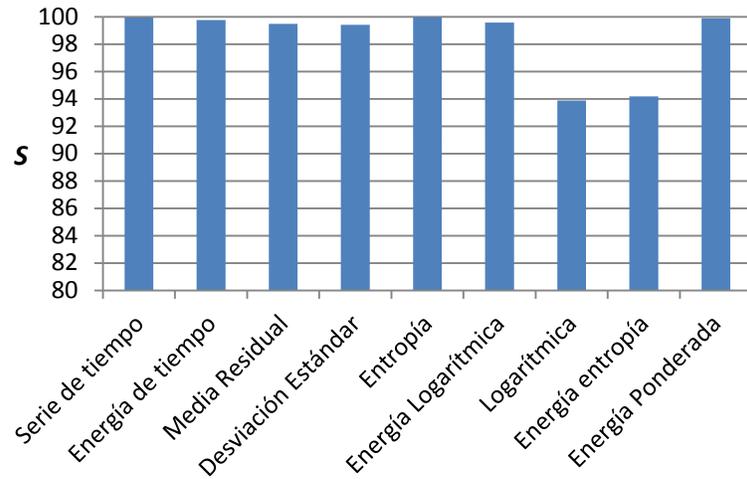
Imágenes rotadas	Serie tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
0°	99.75	99.38	99.55	99.10	99.84	99.81	94.32	94.32	99.75
1°	99.69	99.16	99.44	98.76	99.82	99.78	88.33	88.33	99.69
2°	99.68	99.11	99.43	98.69	99.82	99.79	90.85	90.85	99.69
3°	99.68	99.12	99.42	98.69	99.81	99.77	90.36	90.36	99.68
4°	99.68	99.14	99.42	98.74	99.82	99.79	90.43	90.43	99.68
5°	99.64	98.97	99.36	98.46	99.80	99.77	93.83	93.83	99.64
6°	99.64	99.03	99.35	98.57	99.79	99.74	93.89	93.89	99.65
7°	99.63	99.06	99.34	98.64	99.79	99.76	93.80	93.80	99.64
8°	99.61	98.93	99.31	98.44	99.79	99.77	93.23	93.23	99.63
9°	99.60	99.03	99.29	98.64	99.77	99.73	94.08	94.08	99.62
10°	99.60	99.01	99.28	98.61	99.78	99.75	90.86	90.86	99.61
20°	99.39	98.48	98.90	97.84	99.64	99.59	91.72	91.72	99.40
30°	99.61	98.77	99.29	98.10	99.78	99.74	89.63	89.63	99.62
40°	99.14	97.35	98.45	95.95	99.54	99.49	90.61	90.61	99.14
50°	98.69	96.47	97.63	94.78	99.25	99.13	87.78	87.78	98.66
60°	98.64	96.32	97.54	94.59	99.23	99.09	86.75	86.75	98.66
70°	99.37	98.78	98.87	98.43	99.55	99.46	93.12	93.13	99.36
80°	99.65	99.24	99.38	98.97	99.78	99.74	94.45	94.45	99.67
90°	99.73	99.36	99.51	99.08	99.82	99.78	90.59	90.59	99.73
180°	99.74	99.37	99.53	99.09	99.83	99.80	89.95	89.95	99.74
270°	99.73	99.36	99.51	99.08	99.79	99.76	93.80	93.80	99.74
Promedio similitud	99.52	98.73	99.13	98.15	99.72	99.67	91.54	91.54	99.52

Tabla 5.5 Resumen Series SCM tipo 1. Montaña

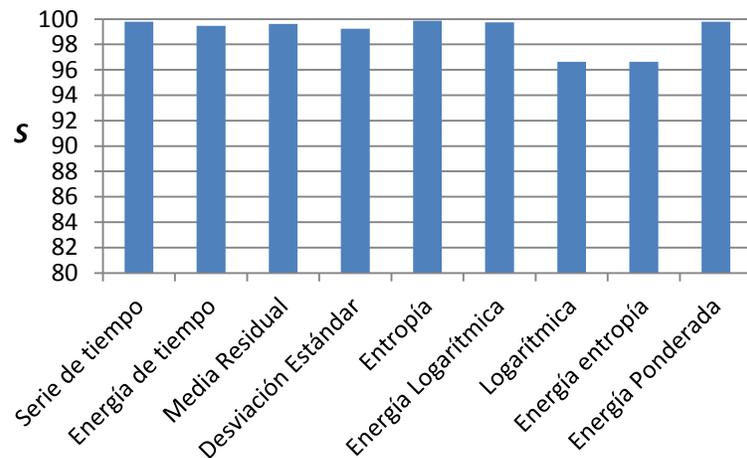
Montaña Rotado SCM	Serie tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
Montaña1	99.52	98.73	99.13	98.15	99.72	99.67	91.54	91.54	99.52
Montaña2	99.88	99.60	99.78	99.37	99.94	99.93	96.91	96.92	99.89
Montaña3	99.82	99.55	99.76	99.43	99.85	99.42	97.88	97.88	99.84
Montaña4	99.84	99.51	99.66	99.12	99.90	99.90	98.18	98.18	99.84
Montaña5	99.91	99.85	99.87	99.83	99.91	99.70	99.81	99.81	99.93
Montaña6	99.79	99.56	99.70	99.47	99.88	99.74	94.46	94.46	99.82
Montaña7	99.79	99.29	99.64	98.91	99.89	99.78	99.88	99.88	99.78
Montaña8	99.87	99.65	99.81	99.53	99.93	99.84	99.45	99.45	99.88
Montaña9	99.76	99.17	99.61	98.77	99.87	99.74	92.39	92.39	99.78
Montaña10	99.91	99.81	99.87	99.77	99.92	99.80	94.06	94.07	99.92
Promedio de similitud	99.80	99.47	99.68	99.23	99.88	99.75	96.45	96.45	99.82



a) Resumen de similitud de los tres tipos de imagen en rotación con PCNN



b) Resumen de similitud de los tres tipos de imagen en rotación con ICM



c) Resumen de similitud de los tres tipos de imagen en rotación con SCM

Figura 5.9 Resumen de los tres paradigmas con 9 series de tiempo o “Firmas”

5.3.2 Casos Escalado

Para el caso de escalado, de igual forma la imagen original fue reducida y recortada por su centro, para la estandarización del tamaño, 128x128 pixeles con un formato JPG. Cada una de las imágenes sufrió una transformación de escalado, se obtuvieron 10 imágenes por cada imagen original (color), con 1%, 2%, 3%, 4%, 5%, 10%, 20%, 30%, 40%, 50% de mayor escala Figura 5.10.

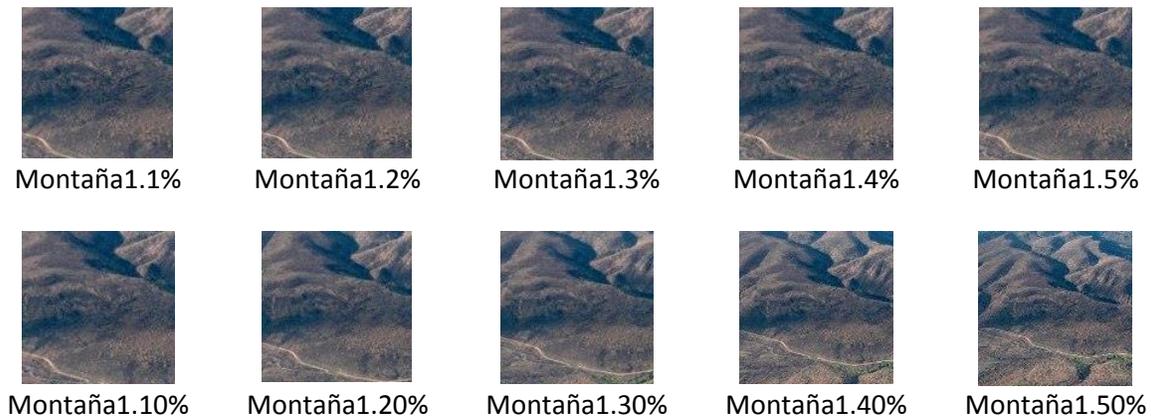


Figura 5.10 Ejemplo de escalado para Montaña 1

Los datos se obtuvieron de las tablas para los casos de rotación, es decir como lo indica la Figura 5.8; las Tablas 5.6, 5.7 y 5.8 muestran un ejemplo para una sola imagen del resumen generado de todas las comparaciones entre las imágenes escaladas en los distintos porcentajes de acercamiento.

Tabla 5.6. Comparación con S, para imágenes con escalado PCNN

Montaña1 Escalado PCNN	Serie tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Energía Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
0%	99.99	99.99	99.87	99.80	99.52	98.97	90.46	90.46	99.98
1%	99.99	99.99	99.90	99.83	99.48	98.96	85.98	85.98	99.98
2%	99.99	99.99	99.90	99.84	99.55	99.06	91.28	91.28	99.98
3%	99.99	99.99	99.92	99.87	99.63	99.23	90.14	90.14	99.98
4%	99.99	99.99	99.91	99.85	99.59	99.15	91.63	91.63	99.98
5%	99.99	99.99	99.91	99.85	99.62	99.19	91.91	91.91	99.98
10%	99.99	99.99	99.93	99.88	99.68	99.34	91.32	91.32	99.99
20%	99.99	99.99	99.93	99.88	99.64	99.24	88.47	88.47	99.99
30%	99.99	99.99	99.88	99.81	99.49	98.81	88.40	88.40	99.98
40%	99.99	99.98	99.82	99.68	99.14	98.19	87.14	87.14	99.97
50%	99.97	99.97	99.62	99.39	98.39	97.03	91.06	91.06	99.93
Promedio de similitud	99.81	99.47	99.68	99.24	99.88	99.75	96.43	96.90	99.82

Tabla 5.7 Comparación con S para imágenes con escalado ICM

Montaña1 Escalado ICM	Serie tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
0%	99.67	98.37	97.96	94.92	99.89	99.68	80.72	80.72	99.40
1%	99.60	98.60	97.66	96.47	99.84	99.56	57.30	57.30	99.38
2%	99.63	98.63	97.84	96.35	99.85	99.60	91.18	91.18	99.40
3%	99.75	99.02	98.54	97.24	99.90	99.75	92.10	92.10	99.58
4%	99.68	98.81	98.10	96.84	99.87	99.64	90.84	90.84	99.48
5%	99.70	98.85	98.20	96.86	99.88	99.67	90.66	90.66	99.50
10%	99.74	99.06	98.46	97.51	99.89	99.70	91.30	91.30	99.58
20%	99.75	99.03	98.54	97.23	99.90	99.73	90.82	90.82	99.58
30%	99.64	98.33	97.91	94.97	99.88	99.66	90.52	90.52	99.36
40%	99.24	97.40	95.44	93.48	99.69	99.08	81.05	81.05	98.82
50%	98.72	95.61	92.43	88.69	99.45	98.56	75.39	75.39	97.85
Promedio de similitud	99.56	98.34	97.37	95.50	99.82	99.51	84.72	84.72	99.27

Tabla 5.8 Comparación con S, para imágenes con escalado SCM

Montaña1 Escalado SCM	Serie tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
0%	98.38	96.06	97.06	94.62	99.08	99.09	95.33	95.33	98.35
1%	98.34	95.97	97.03	94.43	99.02	98.96	85.53	85.53	98.32
2%	98.46	96.23	97.23	94.79	99.11	99.08	94.79	94.79	98.44
3%	98.85	97.22	97.93	96.23	99.34	99.35	95.37	95.37	98.84
4%	98.61	96.50	97.50	95.12	99.21	99.19	94.94	94.94	98.59
5%	98.70	96.69	97.66	95.35	99.25	99.23	95.37	95.37	98.68
10%	98.93	97.19	98.07	95.96	99.38	99.33	95.68	95.68	98.91
20%	98.92	97.29	98.05	96.18	99.37	99.33	94.82	94.82	98.94
30%	98.23	95.82	96.84	94.34	99.00	99.00	95.05	95.05	98.20
40%	96.91	91.83	94.38	88.15	98.20	98.06	94.82	94.82	96.85
50%	94.51	85.40	90.09	79.31	96.97	96.94	86.55	86.55	94.44
Promedio de similitud	98.08	95.11	96.53	93.13	98.90	98.87	93.48	93.48	98.05

Tabla 5.9 Resumen SCM, Tipo Montaña

Montaña1 Escalado SCM	Serie tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Energía Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
Montaña1	98.08	95.11	96.53	93.13	98.90	98.87	93.48	93.48	98.05
Montaña2	99.64	99.09	99.34	98.66	99.78	99.75	95.19	95.19	99.66
Montaña3	98.86	96.51	98.42	95.53	99.31	97.57	91.72	91.72	98.92
Montaña4	99.57	98.95	99.12	98.32	99.71	99.65	96.99	96.99	99.56
Montaña5	99.82	99.74	99.76	99.71	99.83	99.42	99.76	99.76	99.87
Montaña6	99.41	99.05	99.17	98.94	99.63	99.12	93.55	93.55	99.54
Montaña7	99.03	97.22	98.37	95.94	99.39	98.98	99.65	99.65	98.96
Montaña8	99.82	99.63	99.73	99.55	99.88	99.74	98.98	98.98	99.84
Montaña9	99.60	98.72	99.35	98.13	99.80	99.65	92.20	92.20	99.62
Montaña10	99.44	98.61	99.23	98.35	99.79	99.22	90.59	90.59	99.62
Promedio de similitud	99.32	98.26	98.907	97.62	99.60	99.19	95.21	95.21	99.36

La Tabla 5.9 muestra los resultados resumen (Promedio), para Tipo 1 (los 10 tipos de montaña). (Todas las tablas en CD).

La Figura 5.11 muestra el resumen tomado de las tres tablas de los tres tipos para las nueve series. De igual forma que la Figura 5.9, esta gráfica muestra una comparación (S) entre las distintas “Firmas” tomadas al ser comparadas las “Firmas” de las imágenes originales con sus respectivas transformaciones de escalado.

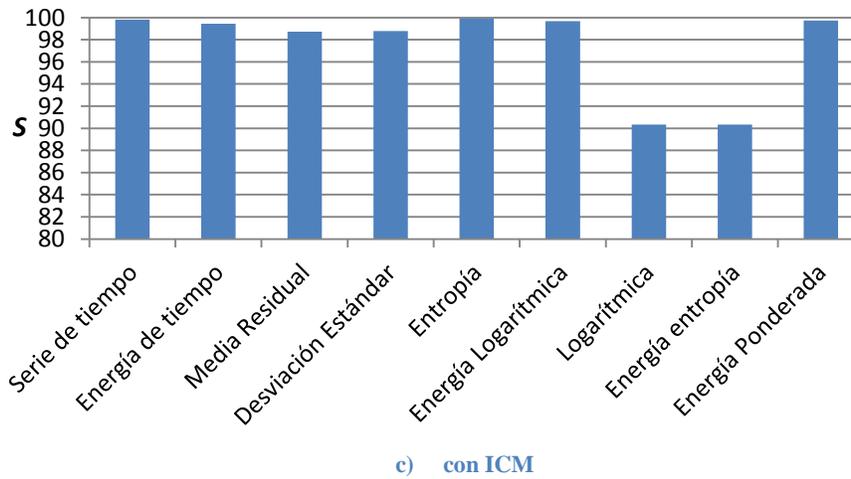
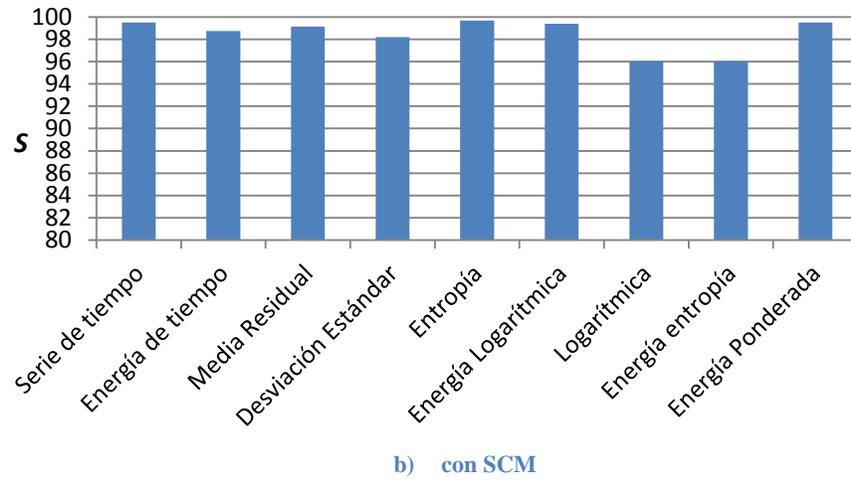
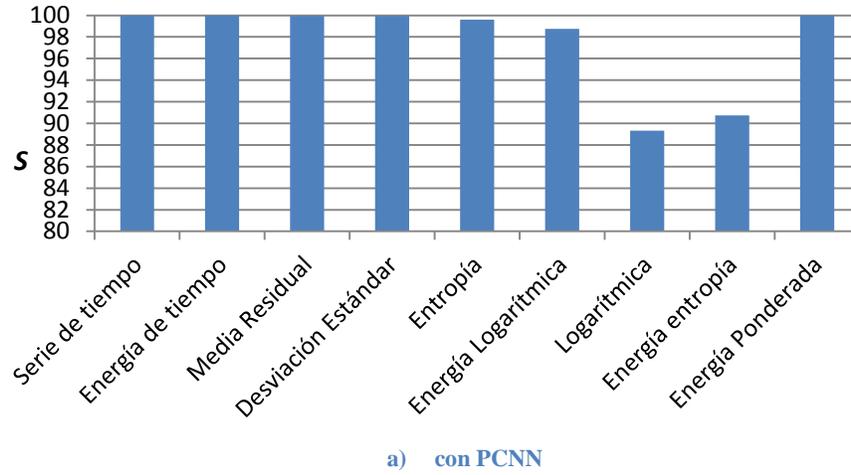


Figura 5.11 Resumen de similitud de los tres tipos de imagen en escalado

5.3.3 Casos Ruido

El caso de las imágenes con ruido, se tomaron las imágenes originales de la base original (30 imágenes) y se les agregó dos clases de ruido, ruido aditivo y ruido impulsivo con los siguientes porcentajes 5%, 10%, 15%, 20%, 25%, y 30% de ruido para cada una de las imágenes (Figura 5.12) seis imágenes con ruido aditivo y seis imágenes con ruido impulsivo. Obteniendo un total de 180 imágenes con ruido Aditivo y 180 imágenes con ruido Impulsivo. Esta sección muestra los resultados de la experimentación realizada a imágenes con las transformaciones de ruido.

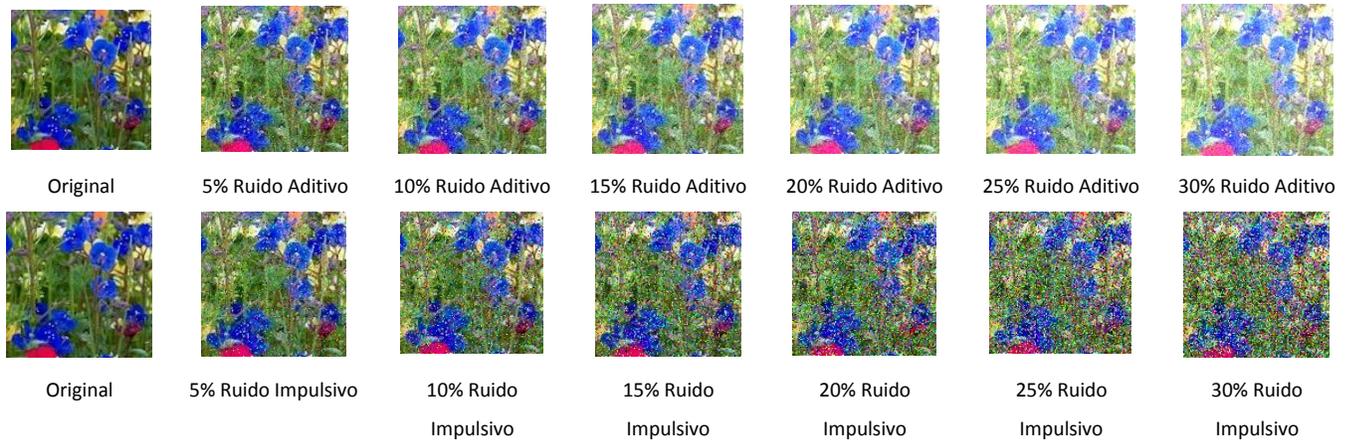


Figura 5.12 Ejemplo de Ruido Aditivo y Ruido Impulsivo

Para el caso de ruido sólo se aplicó el algoritmo SCM, ya que los resultados que mostraron los paradigmas PCNN y ICM, no lograron hacer una gran separación de similitud entre “Firmas” de imágenes distintas (Capítulo 5.2.4), por eso en esta sección sólo se muestran los resultados del algoritmo SCM para las 360 imágenes obtenidas y se calcularon 9 formas distintas de medir una “Firma”, obteniendo un total de 3,240 “Firmas” o series de tiempo.

Para medir la similitud entre las “Firmas” obtenidas se hizo uso de la Ecuación 3.32 (S), la Figura 5.13, muestra un ejemplo del comportamiento de las “Firmas” a ser modificadas las imágenes con distintos grados de ruido aditivo e impulsivo con SCM.

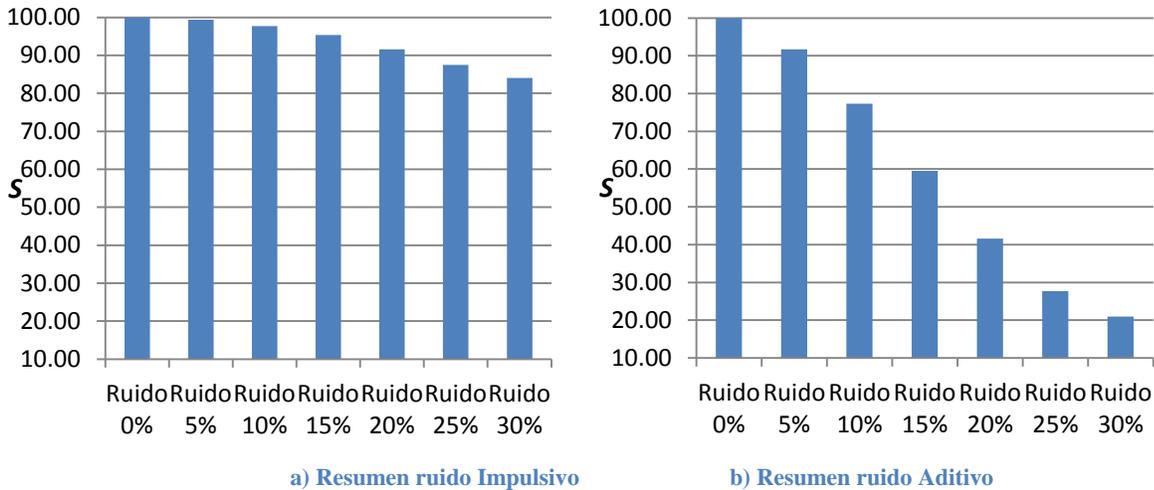


Figura 5.13 Ejemplo de los resultados con $G[n]$, para montaña1 con ruido Impulsivo(a) y ruido Aditivo (b)

De igual manera en que se obtuvieron las tablas (Figura 5.8) para la rotación y escalado se obtuvieron las tablas siguientes. Las tablas 5.10 y 5.11, que muestran un ejemplo de los resultados de las evaluaciones hechas con S (Ecuación 3.32), con las nueve firmas o series de tiempo para la figura Montaña 1 de tipo 1.

Tabla 5.10 Evaluación con S para el caso ruido Aditivo con SCM para Montaña1

Montaña1									
Ruido	Serie	Energía	Media	Desviación	Energía	Energía	Energía	Energía	Energía
Aditivo	tiempo	de	Residual	Estándar	Entropía	logarítmica	Logarítmica	Entrópica	ponderada
0%	59.83	39.88	39.46	34.81	73.56	75.10	76.14	76.14	57.49
5%	74.36	55.88	61.84	50.23	84.86	83.01	78.96	78.96	73.44
10%	80.80	61.64	71.40	54.84	89.27	84.51	81.96	81.96	80.41
15%	83.68	65.55	75.11	58.95	90.53	84.70	85.68	85.68	83.36
20%	81.04	63.79	71.41	57.94	88.43	84.64	84.89	84.89	80.52
25%	73.51	53.39	62.08	48.54	84.50	79.47	81.04	81.04	72.71
30%	66.23	46.58	53.24	42.72	78.67	70.43	74.90	74.90	64.79
Promedio de similitud	74.21	55.24	62.08	49.72	84.26	80.26	80.51	80.51	73.25

Las Figuras 5.14 y 5.15 muestran las gráficas al tomar de las tres tablas de los tres tipos de imágenes para las nueve series. De igual forma que la Figura 5.9, esta gráfica muestra una comparación (S) entre las distintas “Firmas” tomadas al ser comparadas las “Firmas” de las imágenes originales con sus respectivas transformaciones de ruido aditivo y ruido impulsivo.

Tabla 5.11 Tabla resumen para un tipo de imagen (Montaña)

Montaña	Serie de tiempo	Energía de tiempo	Media Residual	Desviación Estándar	Entropía	Energía logarítmica	Logarítmica	Energía Entrópica	Energía ponderada
Montaña1	74.21	55.24	62.08	49.72	84.26	80.26	80.51	80.51	73.25
Montaña2	90.34	74.44	86.40	68.46	96.74	91.88	87.65	87.65	90.82
Montaña3	76.65	59.78	70.04	55.34	88.24	82.26	87.18	87.18	78.76
Montaña4	82.16	62.63	71.20	55.01	89.71	86.80	84.16	84.16	80.43
Montaña5	75.93	58.12	66.39	52.92	87.84	86.14	87.09	87.09	77.43
Montaña6	78.64	60.12	71.49	55.13	91.65	89.17	85.59	85.59	80.87
Montaña7	85.89	71.03	70.03	63.63	91.53	91.83	91.08	91.08	85.36
Montaña8	82.18	63.70	75.23	58.17	93.44	91.83	87.19	87.19	84.22
Montaña9	84.36	72.87	77.13	68.92	90.28	86.81	82.25	82.25	84.30
Montaña10	80.08	62.60	73.90	57.76	91.00	86.00	81.54	81.54	81.46
Promedio de similitud	81.04	64.05	72.38	58.50	90.46	87.29	85.42	85.42	81.68

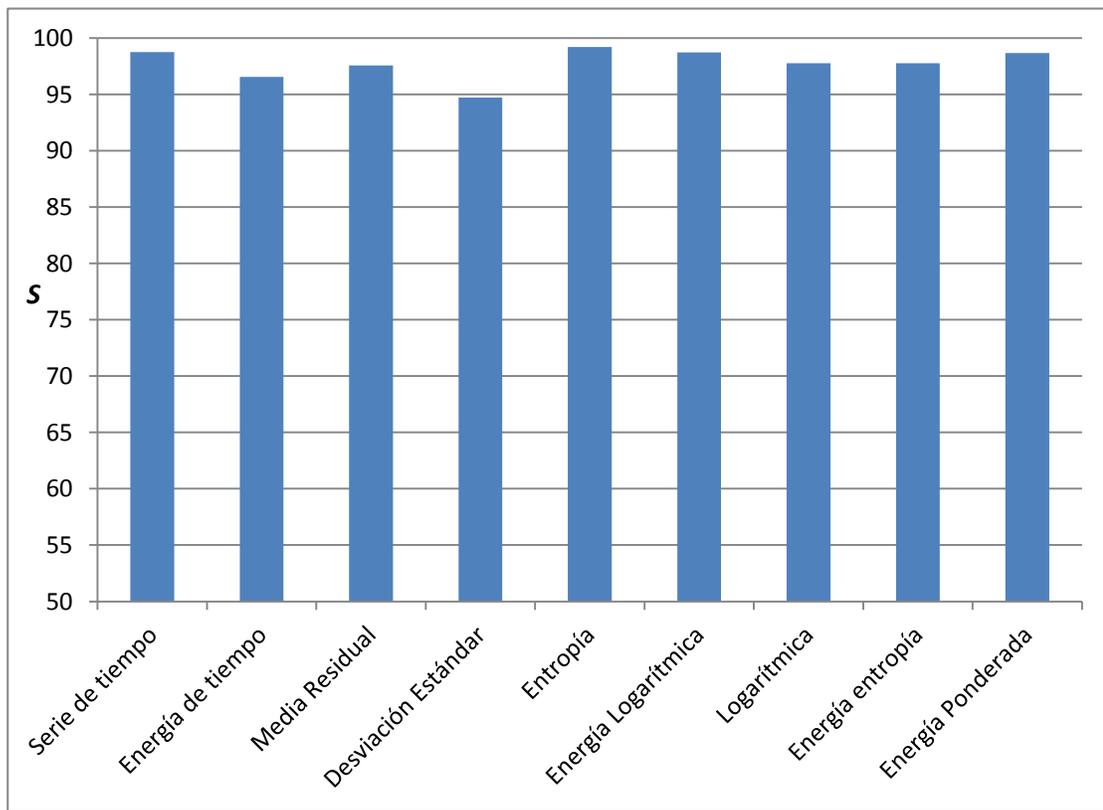


Figura 5.14 Resumen de los tres tipo de imagen con ruido impulsivo con SCM

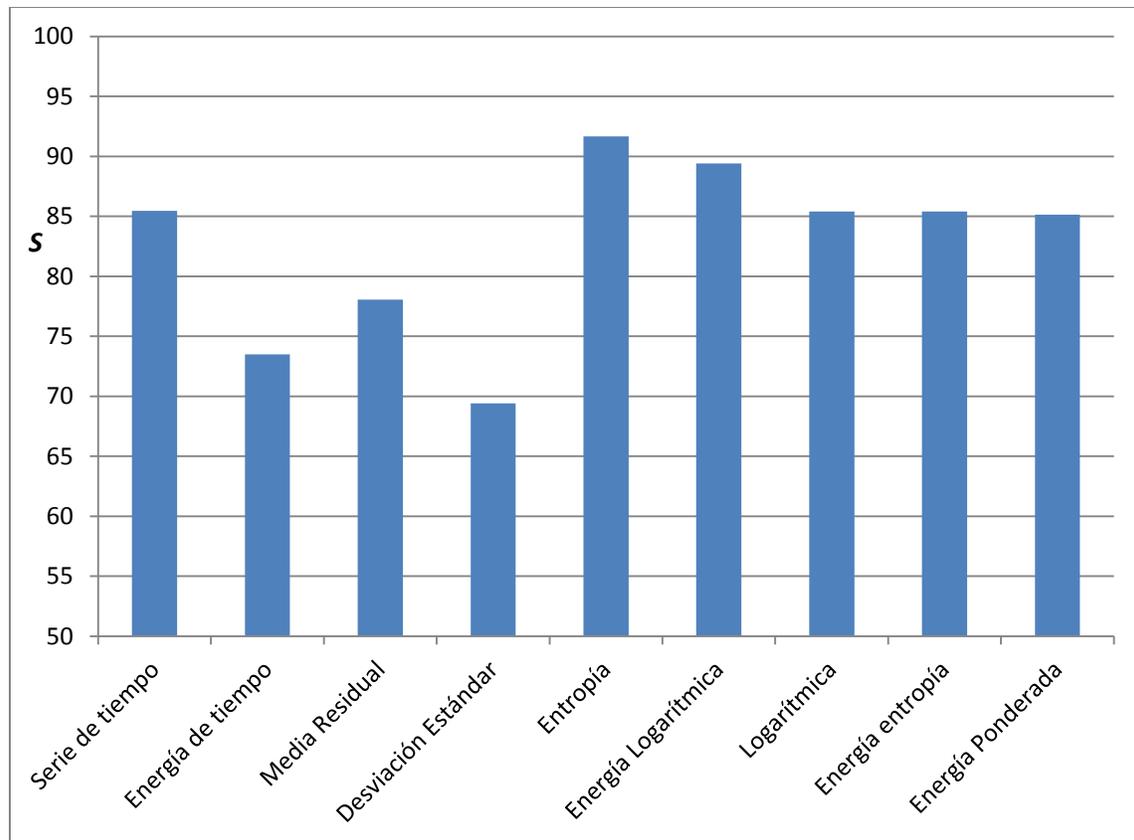
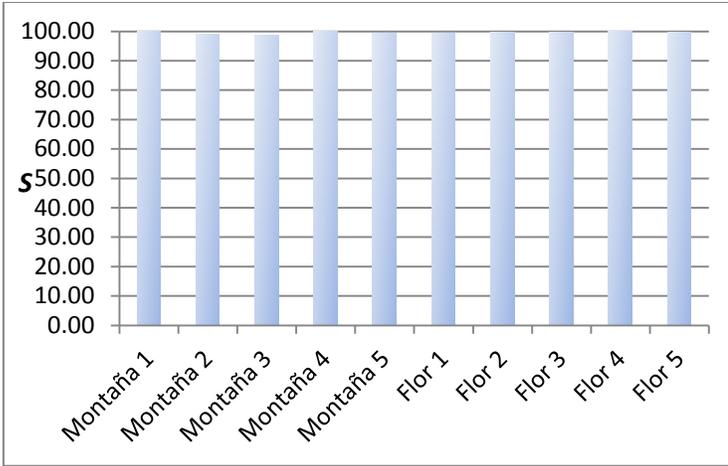


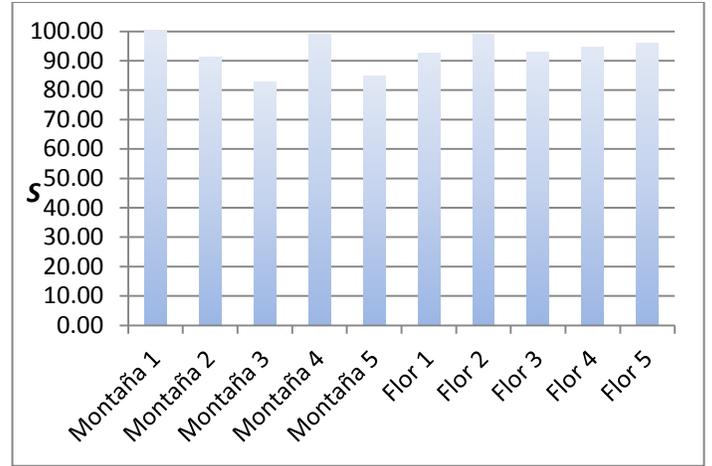
Figura 5.15 Resumen de los tres tipo de imagen con ruido aditivo con SCM

5.3.4 Comparaciones entre imágenes

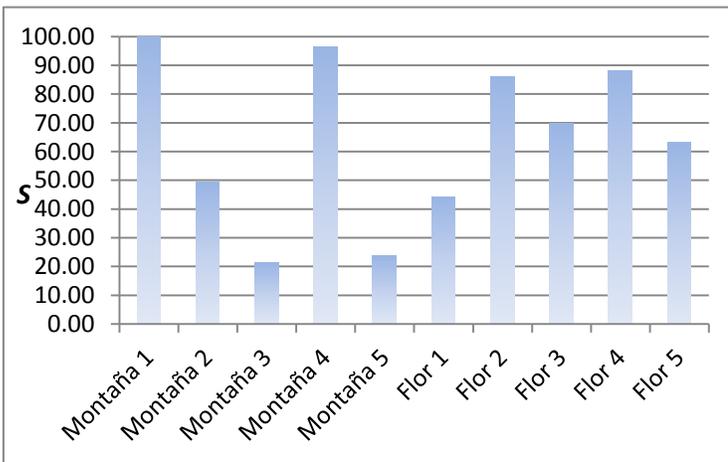
Después de observar el comportamiento de las redes neuronales pulsantes para obtener características de la generación de imágenes binarias a partir de una imagen digital con transformaciones de rotación y escalado, la comparación de distintos tipos de imágenes (“Firmas”) se experimentó haciendo uso de la evaluación (S), se observa el comportamiento de las “Firmas” que generan las imágenes ya sean similares o distintas en la Figura 5.16.



a) PCNN Tipo Montaña y Flor



b) ICM Tipo Montaña y Flor



c) SCM Tipo Montaña y Flor

Figura 5.16 Comparación entre imágenes de distinto tipo con RNPs para tipo Montaña1 vs Montañas y Flores con (S)

Las Tablas 5.12 5.13 y 5.14 muestran los resultados al hacer uso de la evaluación S (Ecuación 3.32). Las tablas muestran sólo una comparación de 5 figuras de los 3 tipos, es decir se compara la “Firma” de una imagen con otra imagen de distinto e igual tipo. Posteriormente esto se hace con todas las imágenes. Las tablas 5.12 5.13 y 5.14 muestran la tabla completa sólo para la serie $G[n]$ con los tres paradigmas pulsantes PCNN, ICM, SCM. (Tablas completas en CD)

Tabla 5.12 Comparación PCNN Montaña y Flor (Serie de tiempo G[n])

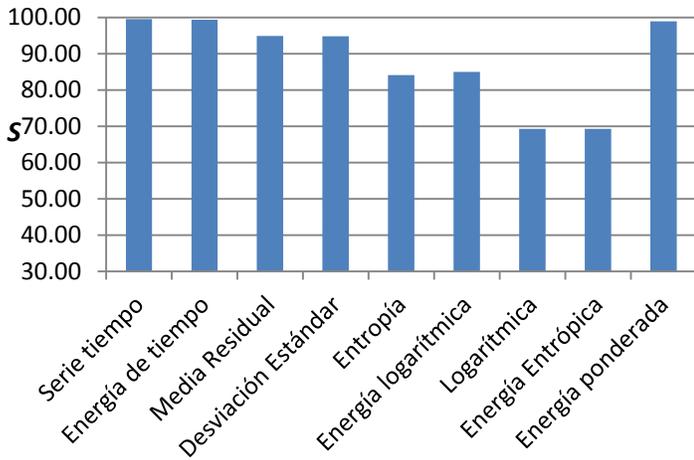
PCNN	Mon 1	Mon 2	Mon 3	Mon 4	Mon 5	Flor 1	Flor 2	Flor 3	Flor 4	Flor 5	Promedio
Montaña 1	100.00	99.16	98.77	99.99	99.32	99.28	99.86	99.67	99.90	99.75	99.57
Montaña 2	99.16	100.00	99.95	99.33	99.93	99.97	99.66	98.27	98.69	99.81	99.48
Montaña 3	98.77	99.95	100.00	98.98	99.88	99.90	99.39	97.83	98.27	99.62	99.26
Montaña 4	99.99	99.33	98.98	100.00	99.46	99.44	99.92	99.59	99.84	99.59	99.61
Montaña 5	99.32	99.93	99.88	99.46	100.00	99.93	99.71	98.68	98.98	99.88	99.58
Flor 1	99.28	99.97	99.90	99.44	99.93	100.00	99.75	98.39	98.81	99.87	99.53
Flor 2	99.86	99.66	99.39	99.92	99.71	99.75	100.00	99.23	99.57	99.96	99.71
Flor 3	99.67	98.27	97.83	99.59	98.68	98.39	99.23	100.00	99.92	99.15	99.07
Flor 4	99.90	98.69	98.27	99.84	98.98	98.81	99.57	99.92	100.00	99.47	99.35
Flor 5	99.75	99.81	99.62	99.84	99.88	99.87	99.96	99.15	99.47	100.00	99.73

Tabla 5.13 comparación ICM Montaña vs Flor (Serie de tiempo G[n])

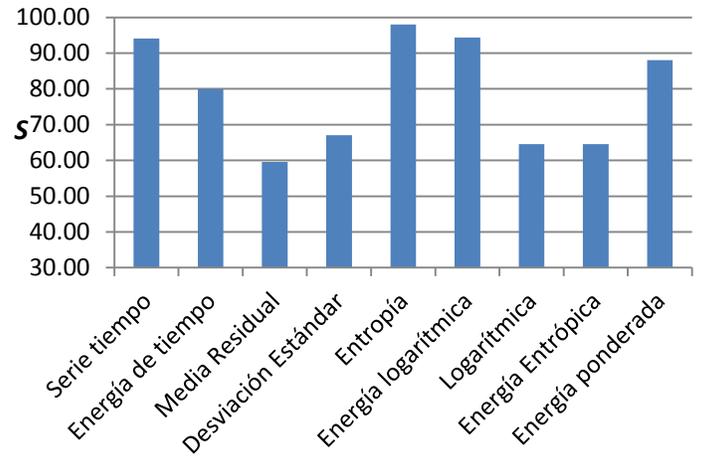
ICM	Mon 1	Mon 2	Mon 3	Mon 4	Mon 5	Flor 1	Flor 2	Flor 3	Flor 4	Flor 5	Promedio
Montaña 1	100.00	91.35	82.89	99.18	84.99	92.62	98.96	92.90	94.46	96.08	93.34
Montaña 2	91.35	100.00	96.20	93.07	95.67	98.45	93.98	84.57	96.94	86.75	93.70
Montaña 3	82.89	96.20	100.00	85.27	99.19	95.04	86.62	77.78	94.66	79.12	89.68
Montaña 4	99.18	93.07	85.27	100.00	87.36	94.40	99.89	93.84	96.38	93.84	94.32
Montaña 5	84.99	95.67	99.19	87.36	100.00	95.85	88.63	81.20	96.32	82.05	91.13
Flor 1	92.62	98.45	95.04	94.40	95.85	100.00	95.16	84.91	97.73	87.37	94.15
Flor 2	98.96	93.98	86.62	99.89	88.63	95.16	100.00	93.87	97.05	96.96	95.11
Flor 3	92.90	84.57	77.78	93.84	81.20	84.91	93.87	100.00	90.18	98.44	89.77
Flor 4	94.46	96.94	94.66	96.38	96.32	97.73	97.05	90.18	100.00	92.49	95.62
Flor 5	96.08	86.75	79.12	97.23	82.05	87.37	96.96	98.44	92.49	100.00	91.65

Tabla 5.14 Comparación SCM Montaña vs Flor (Serie de tiempo G[n])

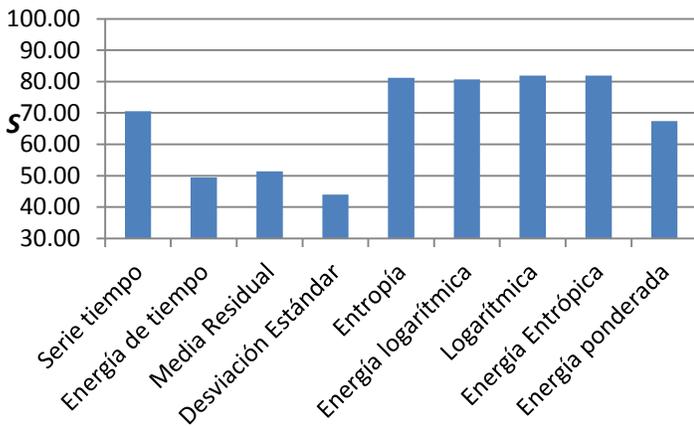
SCM	Mon 1	Mon 2	Mon 3	Mon 4	Mon 5	Flor 1	Flor 2	Flor 3	Flor 4	Flor 5	Promedio
Montaña1	100.00	49.28	21.36	96.32	23.80	44.40	92.04	87.15	56.61	89.63	91.30
Montaña2	49.28	100.00	80.38	60.34	79.90	86.24	76.28	45.04	92.85	48.48	76.34
Montaña3	21.36	80.38	100.00	31.12	97.50	69.80	36.04	20.24	75.56	26.04	91.30
Montaña4	96.32	60.34	31.12	100.0	34.76	58.60	84.27	70.26	69.40	74.65	75.59
Montaña5	23.80	79.90	97.50	34.76	100.0	88.32	39.58	19.22	89.73	23.48	96.91
Flor 1	44.40	92.04	87.15	56.61	89.63	100.0	75.08	30.12	94.92	33.47	82.15
Flor 2	86.24	76.28	45.04	92.85	48.48	75.08	100.0	56.18	87.28	68.83	62.22
Flor 3	69.80	36.04	20.24	75.56	26.04	30.12	56.18	100.0	34.77	90.49	56.70
Flor 4	58.60	84.27	70.26	69.40	74.65	94.92	87.28	34.77	100.0	41.28	62.22
Flor 5	88.32	39.58	19.22	89.73	23.48	33.47	68.83	90.49	41.28	100.0	91.30



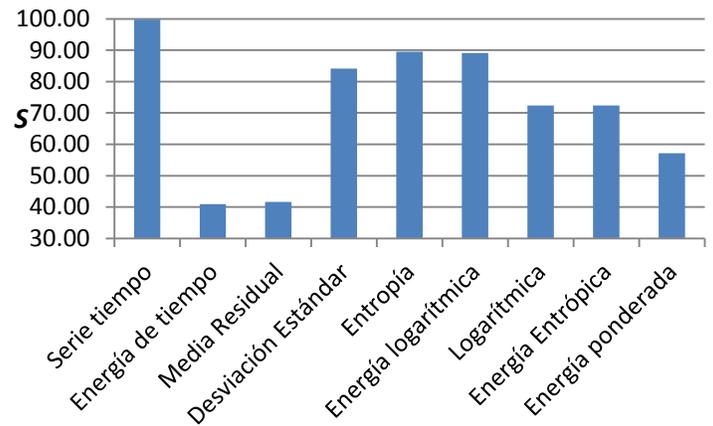
a) Series comparación Montaña y Flor con PCNN



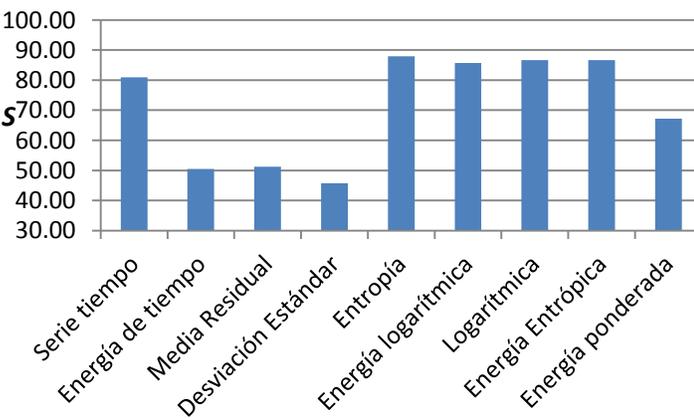
b) Series comparación Montaña y Flor con ICM



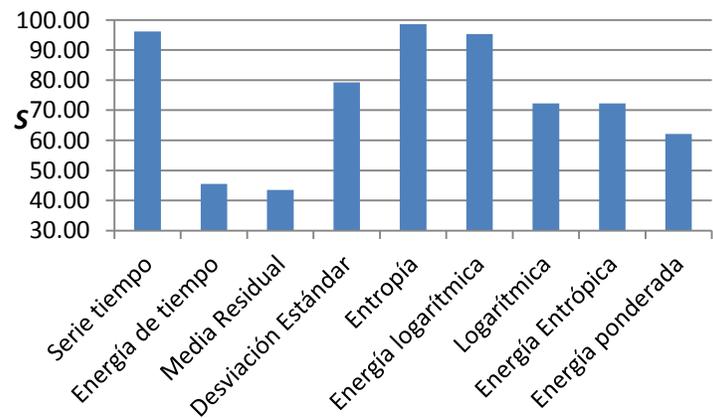
c) Series comparación Montaña y Flor con SCM



d) Series comparación Montaña y Pasto con PCNN

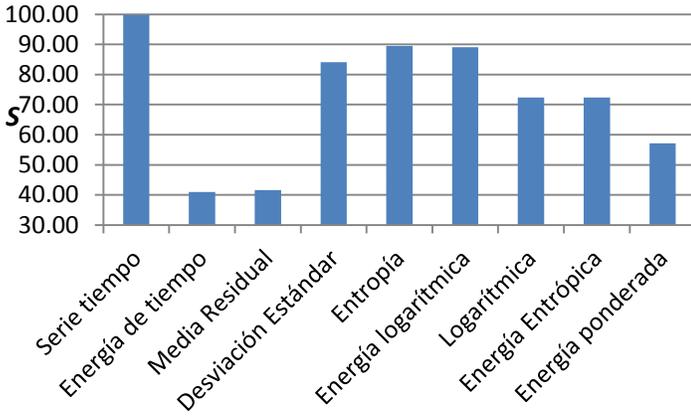


e) Series comparación Montaña y Pasto SCM

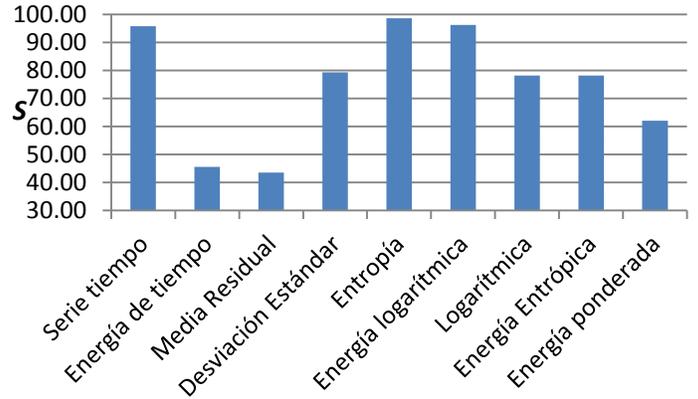


f) Series comparación Montaña y Pasto ICM

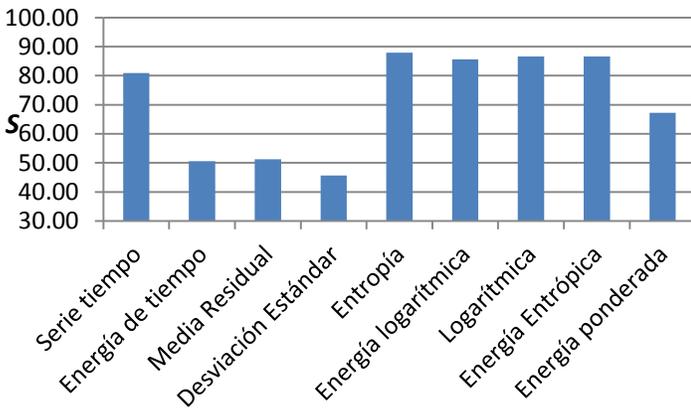
Figura 5.17 Comparación de “Firmas” entre imágenes del mismo y distinto tipo con PCNN, IC y SCM



a) Series comparación Flor y Pasto con PCNN



b) Series comparación Flor y Pasto con ICM



c) Series comparación Flor y Pasto SCM

Figura 5.18 Comparación de “Firmas” de distintos tipos de imágenes con PCNN, ICM, SCM

Las Figuras 5.17 y 5.18 dan un ejemplo de los resultados obtenidos, las gráficas de barras muestran los resultados de las diferencias para las nueve series de los tres paradigmas pulsantes entre los tres tipos de imágenes. Es decir se evaluó con S (Ecuación 3.32), 5 imágenes tomadas al azar de cada tipo de imagen. Para comparar cada una de las imágenes contra todas se seleccionaron 15 imágenes de muestra (Tablas completas en Cd). En estas gráficas se puede ver la discriminación que existe entre imágenes de distinto tipo y entre el mismo tipo.

La Figura 5.19 muestra un promedio general de todas las imágenes originales a color (30 imágenes), con la medida de similitud (S), para las 9 series de tiempo.

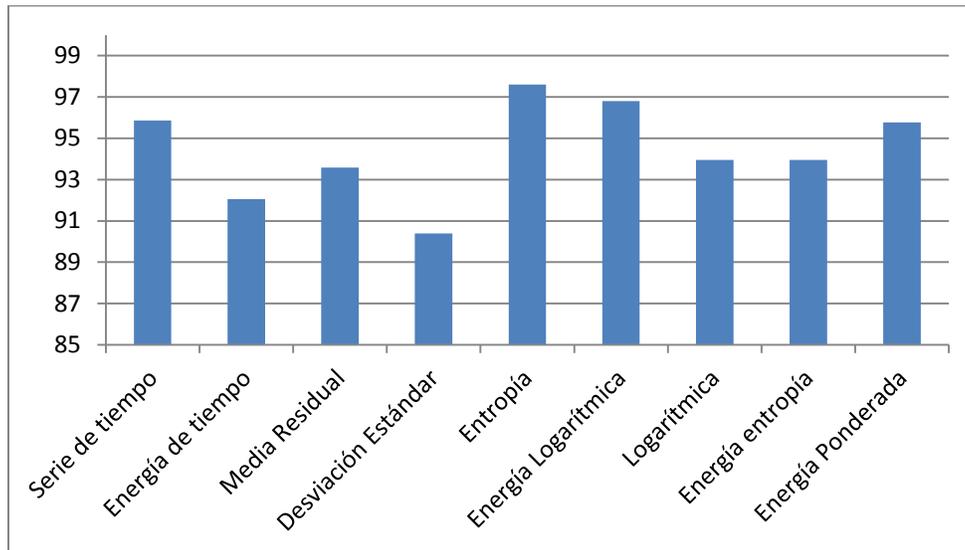


Figura 5.19 Gráfica de similitud para los tres tipos de imágenes, con las nueve series de tiempo

5.3.5 Otras técnicas básicas de extracción de características

Para poder comparar las “Firmas” como obtención de características de una imagen se tomaron en cuenta técnicas de extracción de características de imágenes digitales, tales como media en escala de grises, media para cada canal de RGB y la desviación estándar para cada canal RGB, obteniendo 7 cantidades distintas o un vector de características con 7 elementos por cada imagen, en otra medida de comparación también se obtuvo 7 momentos de tercer orden y 7 momentos de hu , con la ayuda de las funciones de OpenCv. Estos datos son tomados y ordenados en un vector de tamaño 21 con el mismo orden de los datos. Solo se consideran las 30 imágenes principales originales para una comparación con el paradigma SCM.

Estos datos sólo fueron obtenidos para las 30 imágenes originales, es decir 10 de montaña, 10 de flores y 10 de pasto, sin ningún tipo de transformación, con el fin de obtener una especie de “Firma” con los 21 datos obtenidos con la extracción de características, la Tabla 5.15 muestra un ejemplo de los datos extraídos para cada una de las imágenes originales, en su primera columna muestra el nombre de la característica extraída y las siguientes columnas muestran tanto el nombre de la imagen como el valor obtenido de cada imagen al aplicar las funciones y los algoritmos para obtener tales datos con ayuda de las funciones de OpenCv.

Tabla 5.15 Ejemplo de características para cinco imágenes

Características de la imagen	Montana 1	Montana 2	Montana 3	Montana 4	Montana 5
Media en escala de grises	85.5262	165.583	177.284	85.5262	145.761
Media para el canal R	97.6876	184.125	128.087	97.6876	100.53
Media para el canal G	86.1196	170.875	168.992	86.1196	142.672
Media para el canal B	79.7408	148.142	212.063	79.7408	169.056
Desviación estándar para el canal R	16.6799	39.1173	32.0257	16.6799	35.4212
Desviación estándar para el canal G	22.0563	47.0862	31.6191	22.0563	55.3423
Desviación estándar para el canal B	34.1738	64.3657	30.2933	34.1738	77.7126
Momentos de tercer orden (1)	1.40E+06	2.71E+06	2.90E+06	1.40E+06	2.39E+06
Momentos de tercer orden (2)	9.16E+07	1.72E+08	1.91E+08	9.16E+07	1.39E+08
Momentos de tercer orden (3)	8.06E+09	1.42E+10	1.63E+10	8.06E+09	1.15E+10
Momentos de tercer orden (4)	7.95E+11	1.31E+12	1.56E+12	7.95E+11	1.08E+12
Momentos de tercer orden (5)	8.85E+07	1.65E+08	1.84E+08	8.85E+07	1.37E+08
Momentos de tercer orden (6)	5.76E+09	1.04E+10	1.22E+10	5.76E+09	7.84E+09
Momentos de tercer orden (7)	5.05E+11	8.69E+11	1.05E+12	5.05E+11	6.45E+11
Momentos de Hu (1)	0.00207427	0.0009764	0.0009099	0.00207427	0.00114396
Momentos de Hu (2)	2.77E-09	6.01E-09	7.96E-10	2.77E-09	2.60E-09
Momentos de Hu (3)	1.21E-11	4.81E-12	3.15E-13	1.21E-11	7.39E-12
Momentos de Hu (4)	1.11E-11	2.68E-12	9.55E-13	1.11E-11	2.20E-11
Momentos de Hu (5)	-7.04E-23	5.57E-24	3.40E-25	-7.04E-23	-2.80E-22
Momentos de Hu (6)	4.01E-16	1.96E-16	-2.63E-17	4.01E-16	-1.11E-15
Momentos de Hu (7)	-1.07E-22	7.83E-24	3.99E-25	-1.07E-22	-2.24E-23

Estas nuevas “Firmas” o vectores de características obtenidas de las imágenes principales, son comparadas entre ellas mismas, es decir se comparan las 30 nuevas “Firmas” de características de las imágenes principales, para obtener la similitud entre estas nuevas “Firmas”. Por lo tanto se hace uso de la Ecuación 3.32 (*S*), ya que es la ecuación que se utilizó en toda la tesis para obtener la similitud de las “Firmas” de las RNP.

Para la RNP, el caso especial de SCM, se tomaron en cuenta los primeros 21 datos de la “Firma” (que originalmente tiene 100 iteraciones) con la intención de considerar el mismo número de datos obtenidos con las características extraídas anteriormente (media escala de grises y RGB, desviación estándar RGB, momentos de tercer orden, momentos de Hu).

La siguiente tabla es un ejemplo de los datos obtenidos únicamente para las 30 imágenes originales.

La tabla 5.16 muestra el resumen de los resultados de las nueve series. Cabe señalar que los valores presentados en la siguiente tabla muestran un resultado cercano a 100 para cuando las “Firmas” de las imágenes son muy parecidas y cercanos a 0 cuando son totalmente distintas,

cómo se trata de imágenes distintas un número cercano a 100 indicaría que no hace una distinción correcta de las distintas “Firmas”.

La Tabla 5.16 muestra el resumen de las 30 imágenes principales, al comparar las imágenes con la medida de similitud S (Ecuación 3.32), tomando en cuenta para cada imagen el vector que contiene los 21 datos de características comunes de una imagen.

Tabla 5.16 Tabla resumen de la comparación de similitud con S , con los diferentes paradigmas pulsantes

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

En la Tabla 5.16 se pueden observar los resultados de la comparación de las RNPs contra otros métodos de extracción de características de las imágenes, con la medida de similitud de comparación S entre “Firmas” de una imagen. En cada cuarta columna se observa que el paradigma SCM mantiene una mejor separabilidad entre tipo de imágenes distintas, es decir mas cercano a 0. Cabe resaltar que en la experimentación sólo se hace uso de la Ecuación 3.32 para generar los resultados y no de otras medidas de similitud (desechadas por obtener datos difíciles de leer). Por lo tanto según los datos obtenidos por la Ecuación 3.32 se puede deducir que dados los resultados en general, que el paradigma SCM tiene un mejor comportamiento para extraer descripciones de imágenes digitales, ya que genera con mayor facilidad firmas distintas para imágenes distintas. La serie para generar la “Firma” que mejor comportamiento en general tiene es la Entropía $H[p]$ ya que en la mayoría de los casos mostró mejores resultados en cuanto a similitud de rotación, escalado, pero existieron ciertos casos, en especial la similitud de “Firmas” entre imágenes distintas, ya que para estos casos quien tuvo un mejor comportamiento por obtener datos que mejor hacen esta separabilidad, es la serie propuesta en esta tesis, la que se identifica con la energía ponderada (Ecuación 3.15).

En la Tabla 5.17 se muestra la diferencia (o distancia) de cantidades que existe entre la energía ponderada (Serie propuesta en esta tesis) y la entropía, la primer columna de cada serie muestra la cantidad más alta encontrada de similitud entre “Firmas” de imágenes distintas y la segunda columna muestra la cantidad más baja encontrada en la similitud de “Firmas” de imágenes

distintas, la tercer columna se observa cómo la energía ponderada genera una mayor separabilidad entre las “Firmas”.

Tabla 5.17 Comparación de la serie entropía vs energía ponderada, mostrando el mayor número de similitud, tanto el menor, y en la tercer columna la diferencia que existe entre las cantidades, si la diferencia es grande, significaría una mejor separabilidad de “Firmas” entre imágenes distintas

	Energía Ponderada			Entropía		
	Mayor similitud	Menor similitud	Diferencia	Mayor similitud	Menor similitud	Diferencia
Flores	96.67	14.07	82.61	96.79	47.44	49.34
Pasto	99.97	87.77	12.19	99.96	92.88	7.08
Montaña	98.91	11.95	86.97	99.21	41.94	57.26
Flores vs Pasto	97.46	18.63	78.83	98.12	47.86	50.25
Montaña vs Pasto	89.23	34.85	54.38	93.14	65.01	28.13
Flores vs Montaña	92.55	8.37	84.18	94.73	39.74	54.99

5.4 Parámetros

En esta sección se muestran los parámetros usados para los tres tipos de RNP utilizados.

Existen muchas combinaciones de los valores de los parámetros y aún no existe un estándar de los mejores valores de entrada, los siguientes parámetros son propuestos por [Ma, 2010], ya que esta tesis colabora con experimentación realizada con RNPs, los valores no fueron modificados. Tablas 5.18 - 5.20

PCNN

Tabla 5.18 Parámetros utilizado para PCNN

Parámetros	α_L	α_E	α_F	V_F	V_L	V_E	B
Valores	1.0	1.0	0.1	0.80	0.20	20	0.1

$$W = M = \begin{bmatrix} 0.5 & 1.0 & 0.5 \\ 1.0 & 0.0 & 1.0 \\ 0.5 & 1.0 & 0.5 \end{bmatrix}$$

ICM

Tabla 5.19 Parámetros utilizados para ICM

Parámetros	f	g	H	F	Y	E
Valores	0.1	0.9	20	ceros	ceros	unos

$$M = \begin{bmatrix} 0.5 & 1.0 & 0.5 \\ 1.0 & 0.0 & 1.0 \\ 0.5 & 1.0 & 0.5 \end{bmatrix}$$

SCM

Tabla 5.20 Parámetros utilizados para SCM

Parámetros	f	g	H	F	Y	E	Υ
Valores	0.1	0.9	20	ceros	ceros	unos	1

$$M = \begin{bmatrix} 0.1091 & 0.1409 & 0.1091 \\ 0.1409 & 0.0 & 0.1409 \\ 0.1091 & 0.1409 & 0.1091 \end{bmatrix}$$

5.5 Evolución de las “Firmas” o series de tiempo

Las siguientes figuras muestran la evolución de una “Firma” generada por una RNP según su transformación de la imagen, para este caso se escogió el modelo SCM, como imagen de entrada a la red se consideró la imagen “Flor1.JPG” de la base de Datos de imágenes (imágenes completas CD), el resultado de cien iteraciones con la imagen se pudo obtener un resultado final, un vector llamado “Firma”, que para estos casos Figuras 5.20 - 5.23, la “Firma” presentada es la serie de tiempo $G[n]$ (Ecuación 2.19). Para las Figuras 5.20 - 5.23 el color rojo representa la “Firma” original, el azul y verde son las variaciones según su transformada de la imagen (rotación, escalado y ruido).

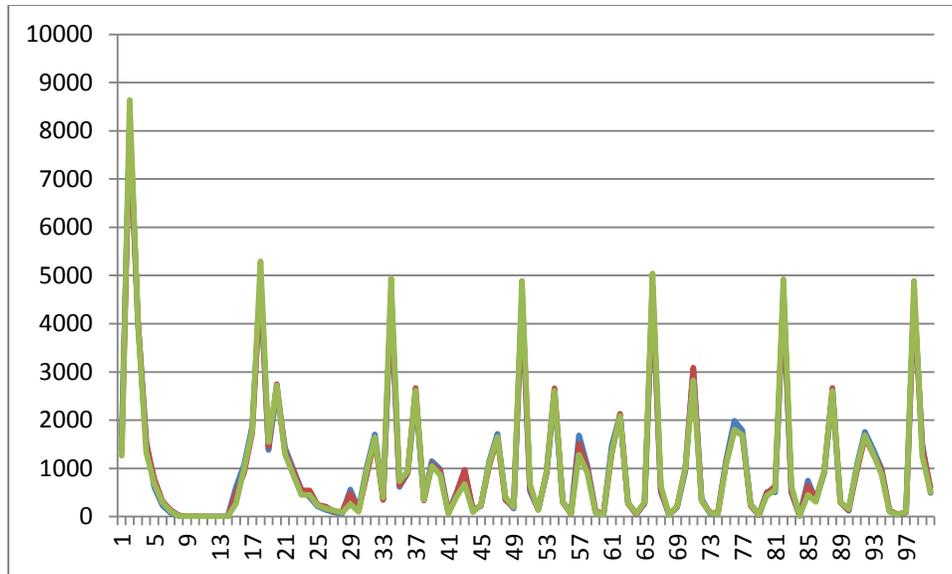


Figura 5.20 Evolución de una “Firma” para rotación con SCM (rojo; “Firma” original, azul; 30° rotados, verde 60° rotados)

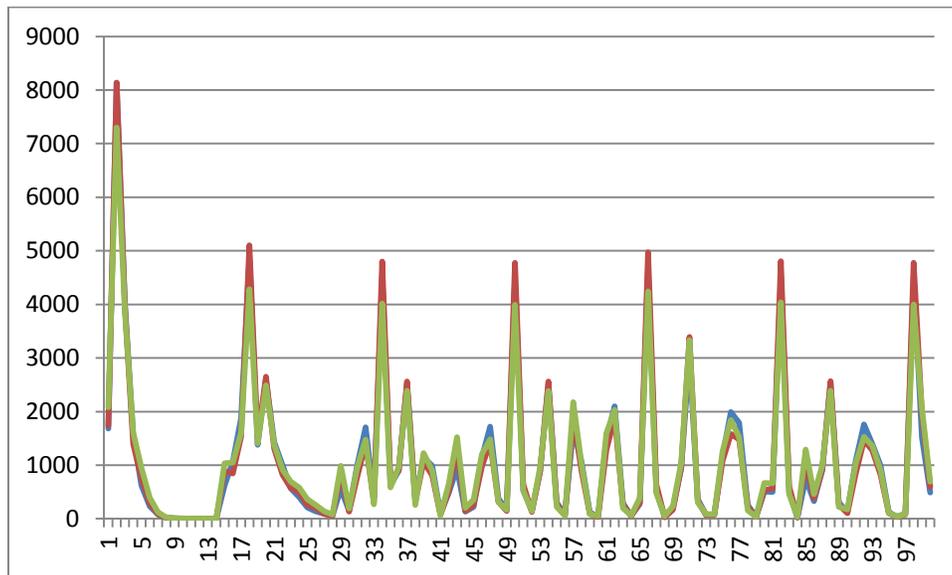


Figura 5.21 Evolución de una “Firma” para escalado con SCM (rojo; “Firma” original, azul; 30%, verde 50%)

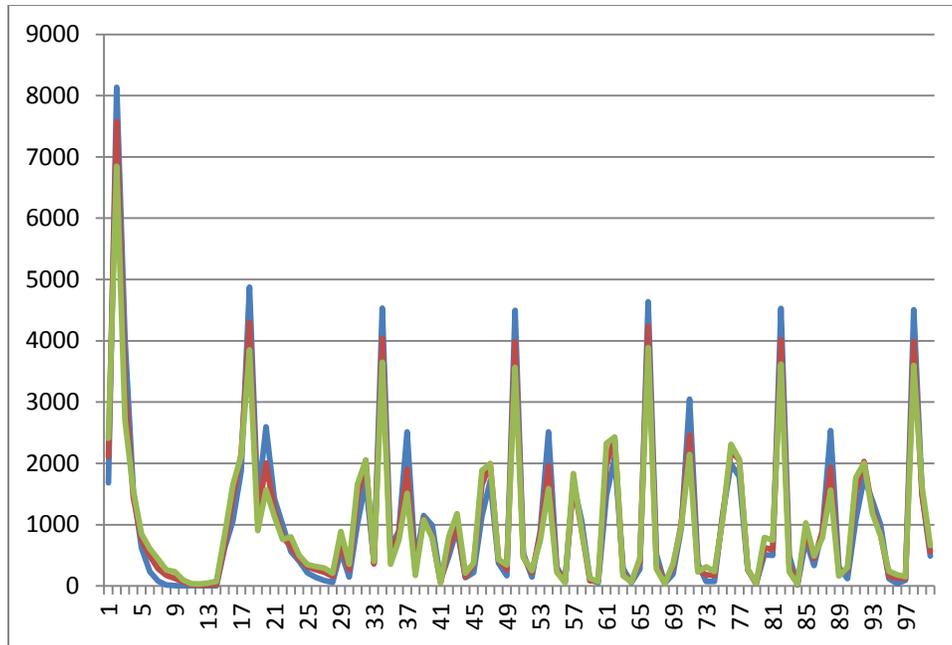


Figura 5.22 Evolución de una “Firma” para ruido impulsivo con SCM (rojo; “Firma” original, azul; 15% ruido impulsivo, verde 30% de ruido impulsivo)

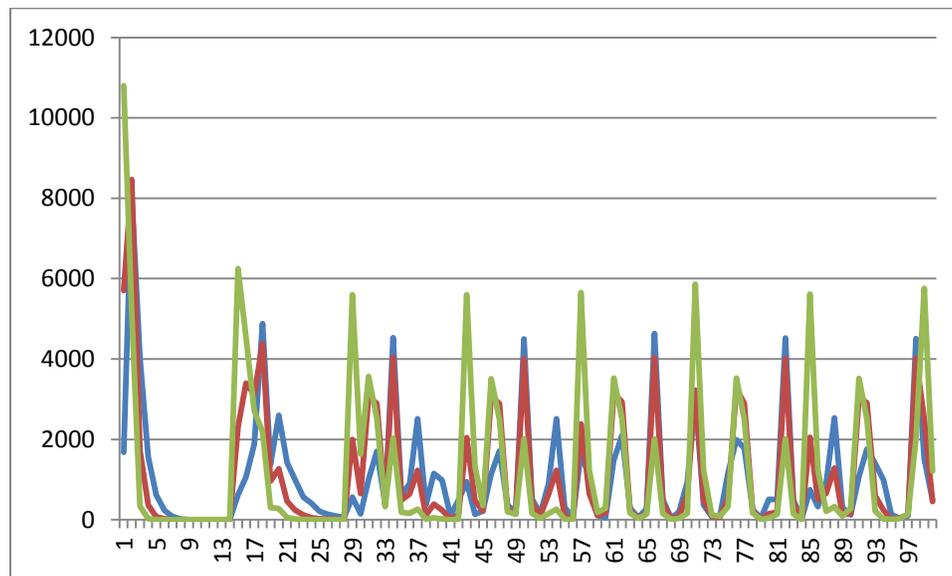


Figura 5.23 Evolución de una “Firma” para ruido aditivo (media=0, y varianza = 0.01) con SCM (rojo; “Firma” original, azul; 15% de ruido aditivo, verde 30% de ruido aditivo)

En las Figuras 5.20 - 5.23, se puede notar la forma en la que una “Firma” de una imagen digital cambia conforme la imagen sufre algún tipo de transformación (rotación, escalado o ruido), las imágenes muestran que la “Firma” es poco alterada al sufrir una transformación de rotación y escalado, existe una pequeña alteración en cuanto al ruido impulsivo(ruido S&P) y sufre una mayor alteración cuando la imagen es alterada con ruido impulsivo (ruido gaussiano), lo cual indica que el aumento de información en los pixeles de una imagen (imagen de entrada) alteran enormemente una “Firma” de una imagen digital.

5.6 Comportamiento de la “Firma”

La siguiente sección muestra cada uno de los nueve comportamientos de las “Firmas” resultantes, según el paradigma utilizado y la ecuación utilizada. Se tomó en cuenta el comportamiento de 15 imágenes principales (5 montañas, 5 flores, 5 pasto), es decir las gráficas muestran la diferencia que existen entre las “Firmas” al ir aumentando el grado de transformación de escalado o rotación de la imagen original (cercano a 100 iguales, cercano a 0 distintas). Las gráficas muestran en color azul el comportamiento de la PCNN, en color rojo el comportamiento de ICM y en color verde el comportamiento de SCM.

En general se puede notar que el comportamiento del paradigma SCM genera una mayor diferencia para la mayoría de las “Firmas” en ambos casos (rotación y escalado) al aumentar el grado de la transformación. Le sigue ICM, finalmente PCNN que genera una “Firma” muy invariante a los grados de transformación realizados, pero observando los resultados anteriores el modelo PCNN también genera “Firmas” invariantes entre imágenes distintas y SCM genera “Firmas” con un mayor grado de invariabilidad entre Firmas de imágenes distintas.

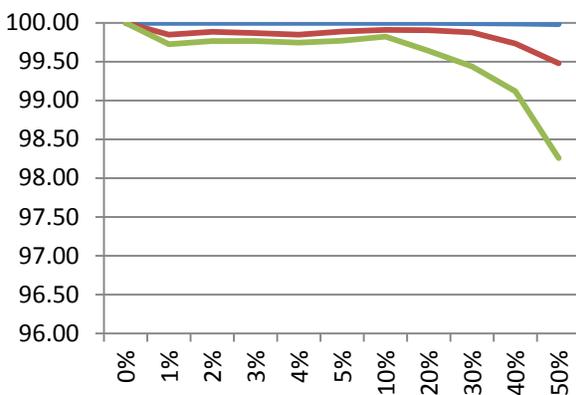


Figura 5.24 Comportamiento de la Serie de tiempo $G[n]$, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.14




Figura 5.25 Comportamiento de la Serie Energía de tiempo, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.15

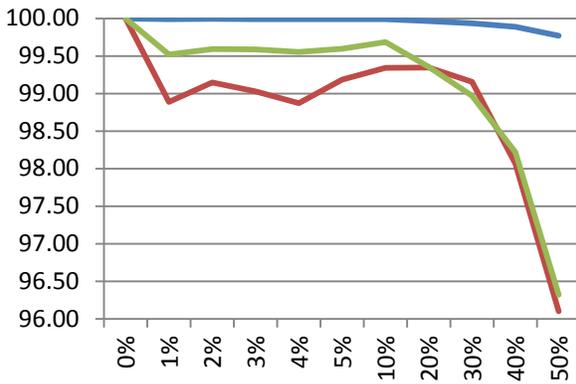


Figura 5.26 Comportamiento de la Serie Media residual, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.16

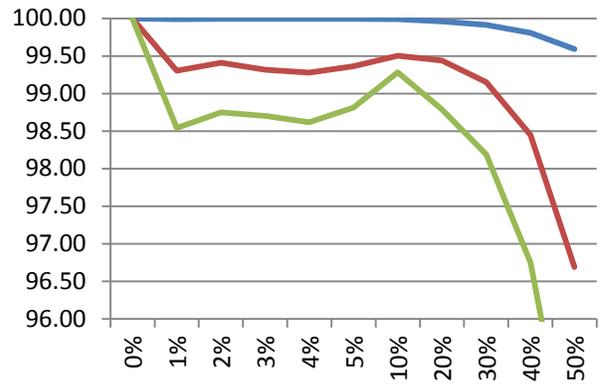


Figura 5.27 Comportamiento de la Serie Desviación estándar, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.17

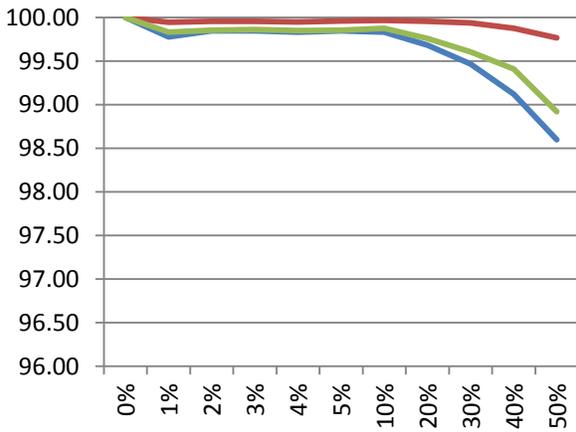


Figura 5.28 Comportamiento de la Serie Entropía, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.19

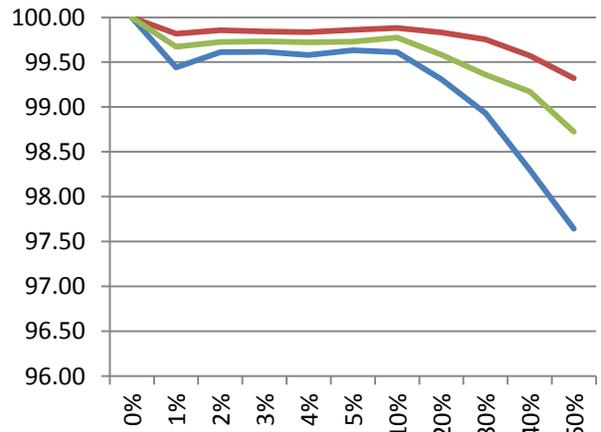


Figura 5.29 Comportamiento de la Serie Energía Logarítmica, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.20

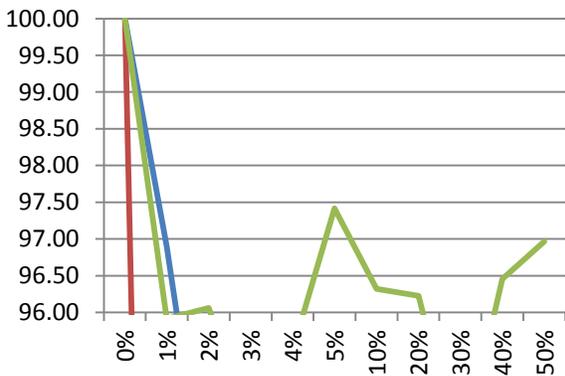


Figura 5.30 Comportamiento de la Serie Logarítmica, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.21

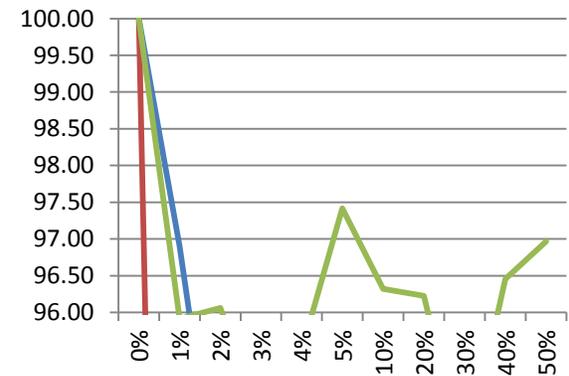


Figura 5.31 Comportamiento de la Serie Energía entrópica, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.22

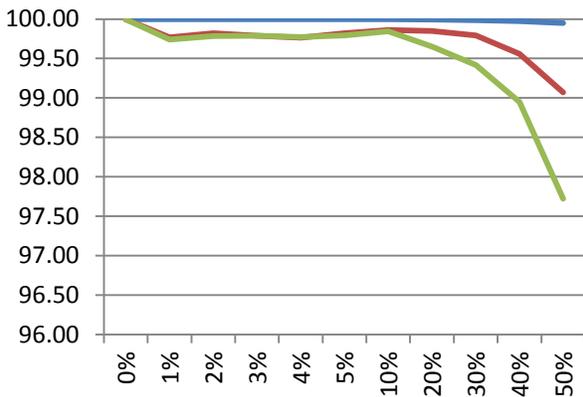


Figura 5.32 Comportamiento de la Serie Ponderada, para figuras con escalado PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.18

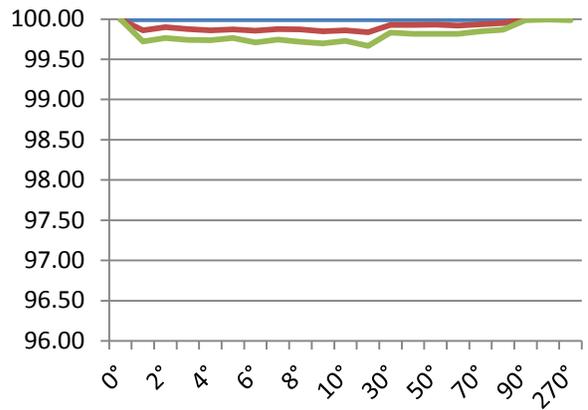


Figura 5.33 Comportamiento de la Serie de tiempo $G[n]$, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.14

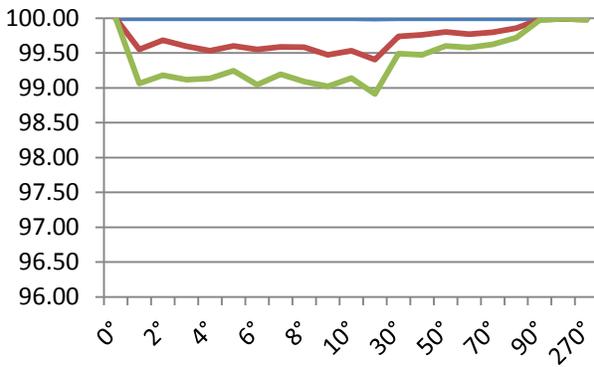


Figura 5.34 Comportamiento de la Serie Energía de Tiempo, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.15

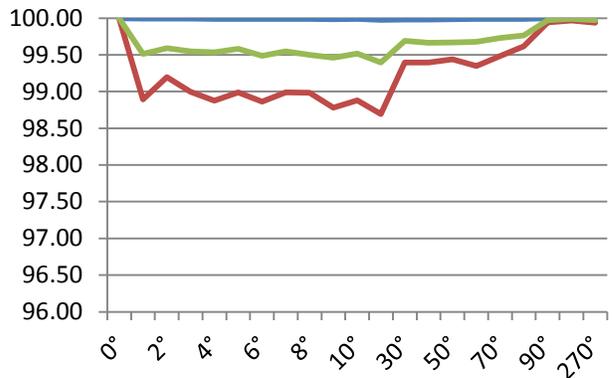


Figura 5.35 Comportamiento de la Media Residual, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.16

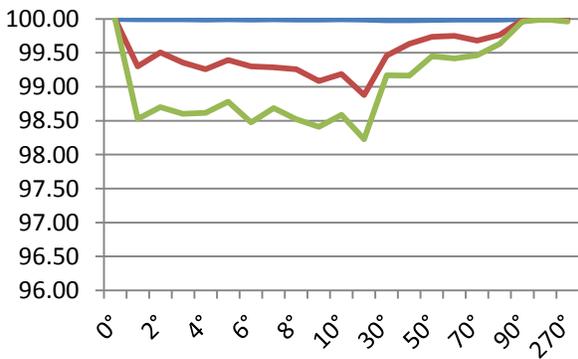


Figura 5.36 Comportamiento de la Desviación Estándar, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.18

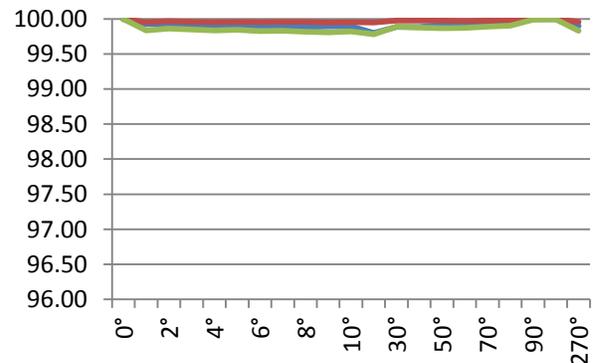


Figura 5.37 Comportamiento de la Entropía, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.19

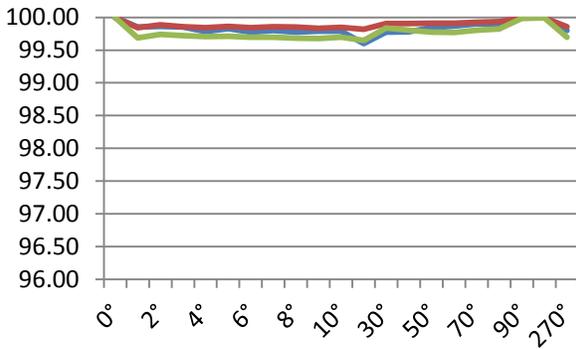


Figura 5.40 Comportamiento de la Energía Logarítmica, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.20

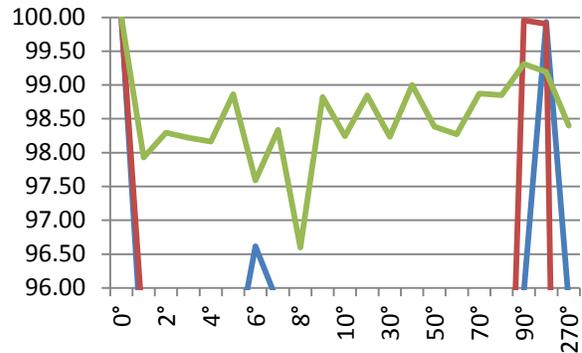


Figura 5.41 Comportamiento de la Serie Logarítmica, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.21

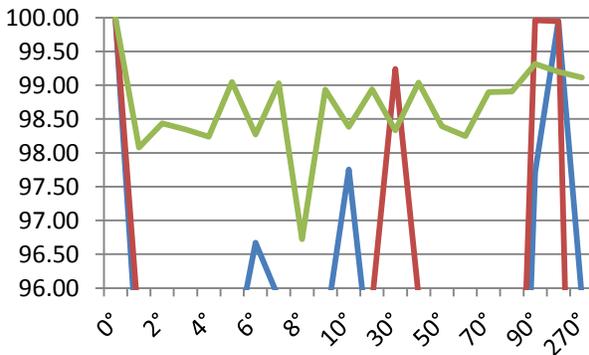


Figura 5.42 Comportamiento de la Serie Entropía, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.22

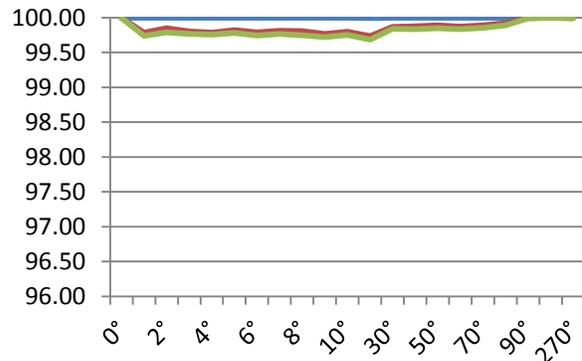


Figura 5.43 Comportamiento de la Serie Desviación Estándar, para figuras con rotación PCNN (color azul), ICM (color rojo), SCM (color verde). Ecuación 3.18

5.7 Discusión

El presente capítulo presentó la experimentación y resultados. Para el caso de la experimentación los parámetros de entrada no fueron modificados, ya que parte de la contribución de esta tesis es la aportación de los resultados a partir de la experimentación de distintos tipos de imágenes, sin modificaciones al algoritmo. Por lo tanto los parámetros no fueron cambiados en ningún experimento. Para las pruebas se integraron cambios de escala, rotación, ruido impulsivo y ruido aditivo. Se obtuvieron nueve "Firmas" distintas de una misma imagen una de ellas llamada serie ponderada es propuesta en esta tesis. Para poder comparar la similitud entre las "Firmas" obtenidas en los resultados, se utilizó una medida de similitud propuesta en esta tesis llamada S . Los tiempos de procesamiento no fueron tomados en cuenta.

De acuerdo a los resultados anteriores se deduce que el paradigma de SCM tiene el mejor comportamiento en general, por lo tanto los experimentos realizados para las imágenes con ruido aditivo y ruido impulsivo sólo se realizaron con el paradigma SCM, ya que los paradigmas

PCNN y ICM, han resultado ineficientes porque crean “Firmas” muy parecidas entre imágenes distintas.

Como ha ganado ampliamente la atención el estudio de las RNPs en la reducción de ruido de una imagen como una técnica de filtrado no lineal, los métodos basados en RNPs convencionales generalmente son combinados con un filtro de mediana o paso a paso o modificando algoritmo, pero existen principalmente dos problemas. Uno es el filtrado por la falta de definición del borde al suavizar una imagen. Dos, es difícil de estimar correctamente los parámetros de las RNPs, ya que aún no existe una estandarización de los parámetros.

5.8 Conclusiones

Rotación

- En la experimentación de imágenes tipo montaña con relación a la transformación de rotación con el paradigma PCNN, se encontró al comparar las “Firmas” de montaña con S , que la serie de tiempo $G[n]$ obtuvo resultados muy aproximados a 100, y las series logarítmica y serie energía entropía obtuvo los resultados más bajos con 82.37.
- En la experimentación de imágenes tipo flor con relación a la transformación de rotación con el paradigma PCNN, se encontró al comparar las imágenes de flor con S , que la serie de tiempo $G[n]$ obtuvo resultados muy aproximados a 100, y la serie logarítmica obtuvo los resultados más bajos con 89.33.
- En la experimentación de imágenes tipo pasto con relación a la transformación de rotación con el paradigma PCNN, se encontró al comparar las “Firmas” de pasto con S , que la serie de tiempo $G[n]$ obtuvo resultados muy aproximados a 100, y las series logarítmica y serie energía entropía obtuvieron los resultados más bajos con 82.37.
- En la experimentación de imágenes tipo montaña con relación a la transformación de rotación con el paradigma ICM, se encontró al comparar las “Firmas” de montaña con S , que la entropía $H[p]$ obtuvo resultados cercanos a 99.99, y las series logarítmica y serie energía entropía obtuvieron los resultados más bajos con 76.62.
- En la experimentación de imágenes tipo flor con relación a la transformación de rotación con el paradigma ICM, se encontró al comparar las “Firmas” de flor con S , que la entropía $H[p]$ obtuvo resultados cercanos a 99.99, y las series logarítmica y serie energía entropía obtuvieron los resultados más bajos con 78.38.

- En la experimentación de imágenes tipo pasto con relación a la transformación de rotación con el paradigma ICM, se encontró al comparar las “Firmas” de pasto con S , que la entropía $H[p]$ obtuvo resultados cercanos a 99.99, y las series logarítmica y serie energía entropía obtuvieron los resultados más bajos con 83.96.
- En la experimentación de imágenes tipo montaña con relación a la transformación de rotación con el paradigma SCM, se encontró al comparar las “Firmas” de montaña con S , que la entropía $H[p]$ obtuvo resultados cercanos a 99.94, y la serie energía entropía obtuvo los resultados más bajos con 91.24.
- En la experimentación de imágenes tipo flor con relación a la transformación de rotación con el paradigma SCM, se encontró al comparar las “Firmas” de flor con S , que la entropía $H[p]$ obtuvo resultados cercanos a 99.93, y las series logarítmica y serie energía entropía obtuvieron los resultados más bajos con 91.74.
- En la experimentación de imágenes tipo pasto con relación a la transformación de rotación con el paradigma SCM, se encontró al comparar las “Firmas” de pasto con S , que la entropía $H[p]$ obtuvo resultados cercanos a 99.92, y las series logarítmica y serie energía entropía obtuvieron los resultados más bajos con 92.81.

Escalamiento

- En la experimentación de imágenes tipo montaña con relación a la transformación de escalamiento con el paradigma PCNN, se encontró al comparar las “Firmas” de montaña con S , que la serie de tiempo $G[n]$ obtuvo resultados muy aproximados a 100, y las series logarítmica y serie energía entropía obtuvieron los resultados más bajos con 82.02.
- En la experimentación de imágenes tipo flor con relación a la transformación de escalamiento con el paradigma PCNN, se encontró al comparar las “Firmas” de flor con S , que la serie de tiempo $G[n]$ obtuvo resultados muy aproximados a 100, y la serie logarítmica obtuvo los resultados más bajos con 81.24.
- En la experimentación de imágenes tipo pasto con relación a la transformación de escalamiento con el paradigma PCNN, se encontró al comparar las “Firmas” de pasto con S , que la serie de tiempo $G[n]$ obtuvo resultados muy aproximados a 100, y las series logarítmica y serie energía entropía obtuvieron los resultados más bajos con 84.84.
- En la experimentación de imágenes tipo montaña con relación a la transformación de escalamiento con el paradigma ICM, se encontró al comparar las “Firmas” de montaña

con S , que Entropía $H[p]$ obtuvo resultados cercanos a 99.97, y las series Logarítmica y serie Energía entropía obtuvieron los resultados más bajos con 81.76.

- En la experimentación de imágenes tipo flor con relación a la transformación de escalamiento con el paradigma ICM, se encontró al comparar las “Firmas” de flor con S , que Entropía $H[p]$ obtuvo resultados cercanos a 99.97, y las series Logarítmica y serie Energía entropía obtuvieron los resultados más bajos con 81.76.
- En la experimentación de imágenes tipo pasto con relación a la transformación de escalamiento con el paradigma ICM, se encontró al comparar las “Firmas” de pasto con S , que Entropía $H[p]$ obtuvo resultados cercanos a 99.97, y las series Logarítmica y serie Energía entropía obtuvieron los resultados más bajos con 82.22.
- En la experimentación de imágenes tipo montaña con relación a la transformación de escalamiento con el paradigma SCM, se encontró al comparar las “Firmas” de montaña con S , que Entropía $H[p]$ obtuvo resultados cercanos a 99.88 y la serie Energía entropía obtuvo los resultados más bajos con 90.59.
- En la experimentación de imágenes tipo flor con relación a la transformación de escalamiento con el paradigma SCM, se encontró al comparar las “Firmas” de flor con S , que Entropía $H[p]$ obtuvo resultados cercanos a 99.89, y las series Logarítmica y serie Energía entropía obtuvieron los resultados más bajos con 92.41.
- En la experimentación de imágenes tipo pasto con relación a la transformación de escalamiento con el paradigma SCM, se encontró al comparar las “Firmas” de pasto con S , que Entropía $H[p]$ obtuvo resultados cercanos a 99.81, y las series Logarítmica y serie Energía entropía obtuvieron los resultados más bajos con 93.34.

Ruido

- En la experimentación de imágenes tipo montaña con relación a la transformación de ruido impulsivo con el paradigma SCM, se encontró al comparar las “Firmas” de montaña con S , que entropía $H[p]$ obtuvo resultados cercanos a 99.73, y la serie desviación estándar obtuvo los resultados más bajos con 80.78
- En la experimentación de imágenes tipo flor con relación a la transformación de ruido impulsivo con el paradigma SCM, se encontró al comparar las “Firmas” de flor con S ,

que entropía $H[p]$ obtuvo resultados cercanos a 99.75, y la serie Desviación estándar obtuvo los resultados más bajos con 86.78

- En la experimentación de imágenes tipo pasto con relación a la transformación de ruido impulsivo con el paradigma SCM, se encontró al comparar las “Firmas” de pasto con S , que entropía $H[p]$ obtuvo resultados cercanos a 99.74, y la serie desviación estándar obtuvo los resultados más bajos con 95.05.
- En la experimentación de imágenes tipo montaña con relación a la transformación de ruido aditivo con el paradigma SCM, se encontró al comparar las “Firmas” de montaña con S , que entropía $H[p]$ obtuvo resultados cercanos a 96.74, y la serie desviación estándar obtuvo los resultados más bajos con 49.72.
- En la experimentación de imágenes tipo flor con relación a la transformación de ruido aditivo con el paradigma SCM, se encontró al comparar las “Firmas” de flor con S , que entropía $H[p]$ obtuvo resultados cercanos a 96.16, y la serie Desviación estándar obtuvo los resultados más bajos con 47.46.
- En la experimentación de imágenes tipo pasto con relación a la transformación de ruido aditivo con el paradigma SCM, se encontró al comparar las “Firmas” de pasto con S , que entropía $H[p]$ obtuvo resultados cercanos a 95.54, y la serie Desviación estándar obtuvo los resultados más bajos con 73.23.

Comparación entre imágenes

- Las similitudes encontradas con PCNN de las “Firmas” tipo montaña y flores al comparar las imágenes con S , la Serie de tiempo $G[n]$ obtuvo resultados cercanos a 99.53, y la serie energía entrópica y logarítmica obtuvieron los resultados más bajos con 69.25.
- Las similitudes encontradas con PCNN de las “Firmas” tipo pasto y montaña al comparar las imágenes con S , la Serie de tiempo $G[n]$ obtuvo resultados cercanos a 99.74, y la serie energía entrópica y logarítmica obtuvieron los resultados más bajos con 73.63.
- Las similitudes encontradas con PCNN de las “Firmas” tipo pasto y flores al comparar las imágenes con S , la Serie de tiempo $G[n]$ obtuvo resultados cercanos a 99.72, y la serie energía entrópica y logarítmica obtuvieron los resultados más bajos con 72.37.
- Las similitudes encontradas con ICM de las “Firmas” tipo montaña y flores al comparar las imágenes con S , la entropía $H[p]$ obtuvo resultados cercanos a 98.03, y la serie media residual obtuvo los resultados más bajos con 59.58.

- Las similitudes encontradas con ICM de las “Firmas” tipo pasto y montaña al comparar las imágenes con S , la entropía $H[p]$ obtuvo resultados cercanos a 98.59, y la serie energía entrópica y logarítmica obtuvieron los resultados más bajos con 72.29.
- Las similitudes encontradas con ICM de las “Firmas” tipo flores y pasto al comparar las imágenes con S , la entropía $H[p]$ obtuvo resultados cercanos a 98.53, y la serie energía entrópica y logarítmica obtuvieron los resultados más bajos con 70.30.
- Las similitudes encontradas con SCM de las “Firmas” tipo montaña y flores al comparar las imágenes con S , la serie logarítmica y energía entrópica obtuvieron resultados cercanos a 81.91, y la serie media residual obtuvo los resultados más bajos con 51.43.
- Las similitudes encontradas con SCM de las “Firmas” tipo pasto y montaña al comparar las imágenes con S , la serie logarítmica y energía entrópica obtuvo resultados cercanos a 87.88, y la serie desviación estándar obtuvo los resultados más bajos con 59.27.
- Las similitudes encontradas con SCM de las “Firmas” tipo flores y pasto al comparar las imágenes con S , en resumen la serie logarítmica y energía entrópica obtuvo resultados cercanos a 89.89, y la serie desviación estándar obtuvo los resultados más bajos con 61.89.

Capítulo VI

Conclusiones

En el presente capítulo se describen las conclusiones de este trabajo de investigación; se divide en objetivos logrados, aportaciones, conclusiones y trabajos futuros.

6.1 Objetivos Logrados

Habiendo alcanzado todos los objetivos específicos, se concluye que se alcanzó el objetivo general, citado a continuación:

Analizar, implementar, experimentar y evaluar la RNA tipo Pulsante (RNP), dentro del dominio de Visión Artificial para problemas de reconocimiento de patrones a través de la extracción de características de una imagen.

Tabla 6.1 Objetivos propuestos contra objetivos logrados

Objetivo propuesto	Objetivo logrado
Desarrollar e implementar computacionalmente el paradigma neuronal Pulsante.	Se implementaron los paradigmas pulsantes PCNN, ICM y SCM.
Definir casos de prueba para las áreas de pre-procesamiento de imágenes y extracción de características dentro de la Visión Artificial para reconocimiento de patrones y realizar la experimentación correspondiente.	Se definieron 3 texturas de imágenes, montañas, flores, pasto, con 10 imágenes para cada textura; cada imagen tiene un total de 42 transformaciones, en rotación, escalado, ruido aditivo y ruido impulsivo.
Identificar y aplicar un mecanismo de evaluación para las redes neuronales tipo Pulsante.	Se eligieron e implementaron 9 tipos para obtener una “Firma” y se una evaluación de similitud entre “Firmas” de las imágenes digitales llamada S (Ecuación 3.32)
Detectar las ventajas y desventajas de las RNP para extraer características de una imagen.	Esto se discute en la sección 6.3.

La Tabla 6.1 presenta los objetivos propuestos y la descripción de los objetivos logrados durante el transcurso de esta investigación.

6.2 Alcances logrados

En este apartado se presentan los alcances inicialmente propuestos y los logrados (Tabla 6.2).

Tabla 6.2 Tabla de alcances propuestos y alcances logrados

Alcances propuestos	Alcances logrados
Estudiar el área de RNAs tradicional.	Se estudiaron las RNAs tradicionales, iniciando con las RNAs de primera generación posteriormente los de segunda generación marco teórico (sección 3), también en el estado del arte (sección 2) se describen varios trabajos relacionados con las RNAs.
Revisar los problemas típicos de las RNAs en el dominio de Visión Artificial para el área de extracción de características.	Se estudiaron los problemas típicos de las RNAs en VA, para extraer características de una imagen digital (sección 3).
Estudiar e implementar la RNP y una variante llamada SCM (por sus siglas en inglés <i>Spiking Cortical Model</i>) importante para problemas de reconocimiento de patrones a través de la extracción de características.	Se estudió e implementó el paradigma SCM. La implementación es en el lenguaje C y C++.
Experimentar con bases de datos de imágenes digitales conocidas en CENIDET para la extracción de características. Realizar un estudio comparativo con técnicas o algoritmos tradicionales pulsantes que extraigan características de una imagen. El tiempo de procesamiento no será relevante.	Se tomó una base de datos de imágenes conocida del CENIDET [Pérez, 2015], que fue modificada para la experimentación correspondiente. Finalmente son imágenes de tres tipos (montañas, flores y pasto) en formato JPG de 128x128 pixeles a color y transformaciones en rotación, escalado, ruido impulsivo y ruido aditivo. Se implementaron los tres principales paradigmas de las RNPs (PCNN, ICM, SCM) para extraer características o “Firmas” de una imagen.
Comparar las RNPs contra técnicas tradicionales de extracción de características.	Se implementó una medida que compara el grado de similitud entre “Firmas” de una imagen. Se extrajeron características de las imágenes principales de la base de datos de imágenes tales como la media de escala en grises y RGB, desviación estándar RGB, momentos de tercer orden y momentos de Hu.

6.3 Aportaciones

Al concluir con el presente trabajo de investigación se obtuvieron aportaciones que se entregan junto con este documento de tesis y se describen a continuación:

- Se planteó un enfoque de estudio para extraer características de una imagen digital o “Firma”, se desconocía si paradigma realmente desempeñaba una aportación a la extracción de características de imágenes digitales. Para esto se integraron variaciones de escala, rotación, ruido aditivo y ruido impulsivo en imágenes de tres distintos tipos (montañas, flores, pasto).
- Se planteó una nueva forma de obtener los datos para extraer características con una RNPs. Modificando la salida para $G[n]$, se propuso una función llamada en este caso energía ponderada (Ecuación 3.28). Las ventajas que ofrecen son una mejor separabilidad de “Firmas” entre imágenes distintas (Tabla 5.16).
- Se planteó una nueva forma de comparar la similitud entre “Firmas” de las imágenes digitales, se propone una función llamada en este caso S (Ecuación 3.32). Se utilizaron distintas formas de comparar los datos durante el proceso de esta tesis, pero los resultados eran muy complicados de leer por ser números muy pequeños, esta medida S llamo la atención al obtener datos más sencillos de leer, cercano a 0 para “Firmas” distintas y 100 para “Firmas” iguales.
- Se generó una base de datos de imágenes con cambios de escala, rotación, ruido aditivo y ruido impulsivo de tres tipos de imágenes: flores, pasto y montañas. Esta base de datos se formó a partir de las imágenes descargadas del sitio web *Corbis* y [Pérez, 2015]. La base de imágenes se encuentra dentro del CD, y están separadas por carpetas para cada tipo de imagen. Donde cada carpeta contiene las imágenes estandarizadas llamadas por *nombre_tipodetransformada_gradodededformacion.jpg* un total de 1290 imágenes.
- Se generó una base de datos de “Firmas”; documentos en .xml (Hojas de cálculo en Excel en CD) de los datos de los vectores resultantes (“Firmas”), así como las tablas resumen total de los experimentos que se presentan a lo largo de esta tesis, para una posible posterior comparación de los resultados de las RNPs.
- En el desarrollo de la tesis, en el estudio del estado del arte y del estado de la práctica se encontró información útil y se consideró importante publicarla, debido a que, como el modelo neuronal es relativamente nuevo hay poca información disponible en español.

6.4 Conclusiones Generales

Con respecto a toda la investigación llevado a cabo y plasmada en este documento se tienen los siguientes puntos concluyentes:

6.4.1 Conclusiones principales

- Las “Firmas” obtenidas con las RNPs elegidas y estudiadas en esta tesis no generan “Firmas” perfectas, es decir existen “Firmas” de imágenes distintas muy parecidas, también existen casos con apenas una diferencia de 3 puntos, por lo tanto dados estos resultados las “Firmas” no son muy buenas para distinguir entre imágenes de distinta clase.
- El problema principal es la interpretación que se les da a las RNPs, no existe documentación clara del proceso que hacen las RNPs, esto ha encaminado a distintas interpretaciones de funcionamiento desde puntos de vista biológico [Hodgkin, 1962], matemático [Ma, 2010], óptico [Jonhson, 1994], eléctrico [Kirchhoff, 1846], computólogo [Ma, 2010].
- Las RNPs y la “Firma” resultante son muy sensibles a factores que el ojo humano no ve, ya que los experimentos con ruido y las “Firmas” de las mismas imágenes obtenidas en distintos sitios resultan distintas.
- La imagen de entrada es en gran parte quien le dará el comportamiento a la RNP, por lo tanto si existen dos imágenes con el mismo gráfico pero de distinto peso (bytes), las “Firmas” obtenidas serán totalmente distintas, es decir el algoritmo no trabaja con la imagen, sino con información que contiene la imagen, esta tipo de investigación se puede llevar a cabo con codificación de mensajes a través de imágenes.
- Dado que las RNPs continúan siendo una caja negra en su comportamiento interno y cómo las deformaciones creadas por las auto-ondas de las imágenes binarias de las RNPs no son controladas, se ha el motivo del por qué la “Firma” resultante no haga tal diferenciación.
- El peor comportamiento de SCM de error se muestra con ruido Aditivo (Gauss), lo cual indica que el aumento de la iluminación afecta a las RNPs seleccionadas.
- Existen muchos algoritmos inspirados en RNP. La PCNN es el estándar de las RNP, pero la falta de una estandarización en los parámetros y el tipo de imagen de entrada dificulta

la exploración completa del paradigma PCNN, mas sin embargo el paradigma pulsante resulta ser novedoso para muchos temas.

Ventajas

- Las imágenes binarias generadas, contienen información de los contornos de los objetos, segmentos y formas, lo cual contienen información de la imagen.
- El algoritmo se puede modificar. Se puede crear un algoritmo basado en el modelo pulsante, respetando el comportamiento de una neurona, haciendo IA.
- Se puede definir el número de iteraciones que tenga el algoritmo. Existen RNPs de un solo pulso (una iteración).
- Se propuso una nueva forma de medir la similitud entre “Firmas”.
- Se puede generar arte de las imágenes binarias pulsantes.

Desventajas

- No existe una forma automática de paro.
- No están estandarizados los parámetros.
- Existen muchas interpretaciones del paradigma pulsante.
- Aún no generan firmas perfectas.
- Los paradigmas PCNN, ICM y SCM no toman en cuenta la posición espacial.
- Las ondas que generan los objetos pueden llegar a crear un grado de error.
- Computacionalmente requiere muchos recursos de memoria, espacio y video.
- No existe una estandarización para medir la similitud de “Firmas”.

6.4.2 Conclusiones personales

Las RNPs aun dependen de una estandarización, ya que los resultados de los experimentos pueden variar mucho en la obtención de los datos, por ejemplo un cambio en alguna de las 8 variables para la PCNN, o el tamaño de la máscara, el tipo de máscara, o el tipo de imagen de entrada, el tamaño de la imagen de entrada, el lenguaje de programación (esto se debe a errores de redondeo), la interpretación de la sinapsis a nivel visual (es decir la interpretación de la convolución como simulación de la sinapsis), la orden de las ecuaciones, todo esto modifican los datos de salida o “Firma” de la imagen haciendo muy complicado establecer una “Firma” única o un orden, un camino a abordar.

Pese a su complejidad el algoritmo tipo pulsante resulta ser muy interesante por el hecho de simular a una neurona biológica, el concepto puede llegar a ser muy novedoso para su

entendimiento total, la falta de experiencia a nivel mundial del uso correcto de los parámetros de entrada de las RNPs, no ayuda a obtener rápidamente mejores resultados, es decir hay que hacer mucha experimentación para que los datos puedan ser comparados. Actualmente las RNPs están siendo útiles para distintos fines dentro de visión artificial, tales como filtrado de imagen, fusión de imágenes extracción de características, codificación de imágenes, hasta para problemas de optimización [Ma, 2010], por lo tanto aún se está explorando la mejor implementación para este paradigma pulsante, así como sus parámetros adecuados, por lo tanto una aportación a este paradigma puede resultar muy importante para la IA.

La documentación existente de los paradigmas PCNN, ICM y SCM, no contiene información clara de la obtención de los resultados o de la implementación de los paradigmas, lo que hace difícil una comparación directa con sus resultados. De acuerdo a los resultados de esta tesis el paradigma PCNN es el que peor comportamiento obtuvo, por lo tanto el paradigma PCNN sólo debe verse como un ejemplo del modelo matemático de la arquitectura del paradigma, ya que la falta de los parámetros adecuados puede resultar a una experimentación muy grande, a menos que se simplifique o mejore el paradigma como por ejemplo ICM y SCM, que son algoritmos que también deben mejorarse.

Las “Firmas” obtenidas con SCM y serie la entropía $H[p]$ es la serie que mejor resaltó en algunos resultados, la serie ponderada estuvo casi siempre situada en segundo puesto, pero en la Tabla 5.17 se hace una diferencia dados los resultados con S, y se observa que la serie ponderada es quien hace una mucho mejor discriminación entre imágenes distintas, por lo tanto se propone la serie ponderada para futuros trabajos relacionados.

6.5 Trabajos Futuros

Durante el desarrollo de esta tesis, se obtuvieron ideas para continuar con la investigación acerca de RNPs y sus aplicaciones:

- Seguir estudiando el paradigma pulsante para mejorar la comprensión del comportamiento real de una RNP.
- Estudiar por que la “Firma” de una imagen es alterada al agregar un poco de ruido aditivo.
- Buscar cuales son los factores reales que hacen que una “Firma” sea sensible.
- Realizar estudios de otros modelos pulsantes, para el análisis de los resultados obtenidos en este trabajo con el fin de detectar si otros algoritmos mejoran las “Firmas” obtenidas con SCM.

- Experimentar con distintos tipos de imágenes; como imágenes de figuras geométricas, letras, números, rostros humanos, imágenes infrarrojas, mapas, etc.
- Mejorar o modificar los Algoritmos pulsantes existentes para una tarea en específico, es decir extracción de características, filtro de imágenes, fusión de imágenes etc. Pero respetando el modelo pulsante:
 - Cambios en la máscara (sinapsis); máscaras que cambien de tamaño, máscara que encuentren pesos adecuados, máscaras intercambiables (como cambios de visión).
 - Ayudando a el algoritmo para extraer características con otro métodos; las “Firmas” son ayudadas con las características extraídas.
 - Proponiendo una nueva forma de emplear el modelo pulsante; el funcionamiento del modelo que indica que envía un tren de pulsos a través de las imágenes binarias pulsantes, un tren de pulsos de un pixel puede ser usado como mensaje codificado dentro de una imagen.

Bibliografía

- [Avellaneda, 2009] Avellaneda Avellaneda Diana, "Caracterización de texturas naturales", Tesis de maestría, CENIDET, Cuernavaca, Morelos, 2009
- [Bloom, 1981] Bloom, S. (1981). *Similarity indices in community studies: Potential pitfalls*. *Marine Ecology-progress Series*, 5:125_128.
- [Camarena, 2009] Camarena García José Felipe, "Análisis Cinemático, Dinámico y Control en Tiempo Real de un Vehículo Guiado Automáticamente", Tesis de maestría, CENIDET, 2009.
- [Canny, 1986] Canny, John "A Computational Approach to Edge Detection" *Pattern Analysis and Machine Intelligence, IEEE Transactions on* (Volume:PAMI-8 , Issue: 6)
- [Cárdenas, 2015] Cárdenas Selene Yosahandy "Implementación y evaluación de redes neuronales "pulse coupled neural networks" Tesis de maestría, CENIDET, Cuernavaca, Mor, 2015.
- [Chacon, 2007] Chacon M. Mario I. y Mendoza P. Jessica A. "A PCNN-FCM Time Series Classifier For Texture Segmentation", 978-1-61284-968-3/11 IEEE, 2011.
- [Chatzichristofis, 2011] Chatzichristo_s, Savvas & Boutalis, Y. (2011). *Compact composite descriptors for content based image retrieval*. VDM Verlag Dr. Müller, USA, 1 edición.
- [Cruz, 2010] Cruz Sánchez V. G., "Metodología para el diseño de Sistemas Híbridos Neuro-Simbólicos aplicados a problemas de inspección Visual, Tesis de maestría, CENIDET, Cuernavaca Mor., 2010.
- [Datta, 2008] Datta, R., Joshi, D., Li, J., y Wang, J. Z. (2008). *Image retrieval: Ideas, influences*.
- [Delgado, 1998] Delgado A., *Inteligencia Artificial y Minirobots*. Textos Universitarios, 1998.
- [Ebied, 2013] H. M. Ebied, K. Revett, M. F. Tolba "Evaluation of unsupervised feature extraction neural networks for face recognition *Neural Computing and Applications*" May 2013, Volume 22, Issue 6, pp 1211-1222 (JCR)
- [Fei, 2008] Shi Fei. "A new impulse noise filter based on pulse coupled neural

- network*” School of Information Science & Engineering, Lanzhou University, Lanzhou 730000, China. 2008
- [Flusser, 2000] J. Flusser: "*On the Independence of Rotation Moment Invariants*", Pattern Recognition, vol. 33, pp. 1405–1410, 2000.
- [Fitz, 1961] Fitzhugh. *Impulses and physiological states in theoretical models of nerve membrane. Biophysical J.* 1:445-466
- [Francis, 2012] Francis Armando Segovia. Acoplamiento excitatorio e inhibitorio de neuronas pulsantes acopladas. Universidad Distrital Francisco José de Caldas. Bogotá Colombia. 2012
- [Galeana, 2008] Galeana Pérez Deysy , " Caracterización automática de imágenes en un dominio transformado", Tesis de maestría, CENIDET, Cuernavaca, Mor, 2008.
- [González, 2006] González Visión por ordenador. I. González Marcos, Ana. II. Universidad de La Rioja. Grupo de Investigación EDMANS. 2006
- [Haiyan, 2008] Haiyan Li. *A new PCNN-based method for segmentation of SAR images.* Control, Automation, Robotics and vision Conference 2008
- [Hernández, 2003] Hernández Mora J. J., "Implementación de una red neuronal holográfica para el control de un brazo robótico articulado", Tesis de Maestría, Cuernavaca, Mor.: CENIDET, 2003.
- [Hodgkin, 1962] Hodgkin Al, Huxley Af. *Currents carried by sodium and potassium ions through the membrane of the giant axon of Loligo.* J Physiol. 1952
- [Hu, 1962] M.K Hu "*Visual Pattern Recognition by Moment Invariants*", IRE Trans. Info. Theory, vol. IT-8, pp.179–187, 1962
- [Johnson, 1994] Johnson John L. "*Pulse-coupled neural nets: translation, rotation, scale, distortion, and intensity signal invariance for images*" Applied Optics: 6239-6253. SEP 1994.
- [Johnson, 1999] Johnson John L. and Padgett Mary Lou. "*PCNN models and applications*", IEEE TRANSACTIONS ON NEURAL NETWORKS, VOL. 10, NO. 3, MAY 1999.
- [Kinsler, 2004] Kinsler J. M *The intersecting cortical model in image processing. Nuclear instruments and methods in physics research 525(1): 392-369*
- [Kirchhoff, 1846] Oldham, Kalil T. Swain (2008). *The doctrine of description: Gustav*

- Kirchhoff, classical physics, and the "purpose of all science" in 19th-century Germany* (Ph. D.). University of California, Berkeley. p. 52. Docket 3331743.
- [Lindblad, 2005] Lindblad T. and Kinser J. M. “ *Image Processing Using Pulse-Coupled Neural Networks*”, 2da Edición, Springer Berlin Heidelberg New York , Septiembre 13, 2005.
- [Liu, 2012] Fu Liu. *Image Fusion Algorithm Based on Simplified PCNN in Nonsampled Contourlet Transform Domain*. College of Electrical and Information Engineering, Hunan International Economics University, ChangSha, 410205, China 2012
- [Lux, 2013] Lux, M. y Marques, O. (2013). Visual Information Retrieval using Java and Lire. Morgan & Claypool Publishers, USA.
- [McCulloch, 1943] McCulloch Warren S. and Pitts Walter, “*A logical calculus of the ideas immanent in nervous activity*”, *Bulletin of Mathematical Biophysics* 5:115-133, 1943
- [Ma, 2010] Yide Ma *Applications of Pulse – Coupled Neural Networks*. Printed by Springer 2010. ISBN 978-3-642-13744-0
- [Majid, 2014] Majid Rafei, “Multi-objective optimization by means of multi-dimensional mlp neural networks” Neural Network World 2014 International journal on non-standard computing and artificial intelligence. (JCR).
- [Martínez, 2012] Martínez Ramírez F., "Control Embebido de un vehículo guiado automáticamente mediante redes neuronales artificiales", Tesis de maestría, CENIDET, Cuernavaca Mor, 2012
- [Meneses, 2008] Meneses Ortiz Luis Eduardo “Modelos para estructurar portafolios de inversiones en acciones en Colombia mediante redes neuronales”, Tesis de grado, Universidad Tecnológica de Pereira, Colombia, 2008.
- [Montaño, 2002] Montaño Moreno Juan José, “Redes Neuronales Artificiales Aplicadas al Análisis de Datos”. Tesis Doctoral, Universitat de les Illes Balears, Facultat de Psicologia, Palma de Mallorca, 2002.
- [Morales, 2013] Morales Garduño Carlos Alberto, “Construcción y Evaluación de una red Neuronal tipo “*Adaptative Bidirectional Associative Memory*”, Tesis de ingeniería, Jiutepec Morelos, UPEMOR, 2013.

- [Nagumo, 1962] Nagumo J., Arimoto S., and Yoshizawa S. (1962) *An active pulse transmission line simulating nerve axon*. Proc IRE. 50:2061–2070.
- [Pérez, 2015] Pedro Pérez Alma Alheli. *Métricas y funciones de semejanza para texturas*. Tesis Maestría. Cenidet 2015
- [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.
- [Ramírez, 2012] Ramírez Quintana J. A., Chacon Murguía M. I. and Chacon Hinojos J. F., “*Artificial Neural Image Processing Applications: A Survey*”, *Engineering Letters*, 20:1, pp. 68-80, 2012.
- [Rocha, 1991] Rocha Sánchez M. A., "Reconocimiento de Patrones de fallas en generadores eléctricos empleando redes neuronales artificiales", Tesis de Maestría, Cuernavaca, Mor.: CENIDET, 1991.
- [Rumelhart, 1986] Rumelhart David E., “*Parallel Distributed Processing*”, MIT PRESS, 1986.
- [Shang, 2006] Lefeng Shang. *Binary Image Thinning Using Autowaves Generated by PCNN*. Computational Intelligence Laboratory School of Computer Science and Engineering. University of Electronic Science and Technology of China. 2006
- [Shi, 2007] Meihong Shi. *A simplified pulse-coupled neuronal network for adaptive segmentation of fabric defects*. *Machine Vision and Applications* 2009 20:131-138
- [Shuiming, 2010] Shuiming He. *Application of Pulse Coupled Neural Network in Image Recognition*. Computing, Control and Industrial Engineering (CCIE), 2010 International Conference on (Volume:2)
- [Tanimoto, 1982] Tanimoto, Katsutoshi; Yoshimoto, Y. (1982). *Theoretical and Experimental Study of Reaction Coefficient for Wave Dissipating Caisson with a Permeable Front Wall*. Report of the Port and Harbour Research Institute, 21:1_36.
- [Troncoso, 2007] Troncoso Rey Perla Aurora, "Indexado y recuperación de imágenes por contenido", Tesis de maestría, CENIDET, Cuernavaca, Mor, 2007
- [Wang, 2010] Wang Zhaobin, Ma Yide, Cheng Feiyan and Yang Lizhen, “*Review of pulse-coupled neural network*”, *Image and vision computing*, Ed.

Elsevier, vol. 28, no. 1, pp. 5-13, Jan 2010.

- [Wei, 2011] Wei Shuo, Hong Qu and Hou Mengshu, “Automatic image segmentation based on PCNN with adaptive threshold time constant”. *Neurocomputing*, 74(9), 1485–1491. doi : 10 . 1016 / j . neucom. 2011.01.005
- [Xiao, 2009] Xiao-Bo QU, Jing-Wen YAN, Hong-Zhi XIAO, and Zi-Quian 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.
- [Zhan, 2009] Zhan Kun, Zhang Hongjuan, and Ma Yide, “New Spiking Cortical Model for Invariant Texture Retrieval and Image Processing”. *IEEE Transactionson Neural Networks*, 20(12), doi : 10.1109 / TNN. 2009. 2030585, 2009.
- [Zhang, 2010] Zhang Yunjun “RS Image PCNN Automatical Segmentation Based on Information Entropy” 2010. 01/2010; DOI: 10.1109/MMIT.2010.24
- [Zhang, 2011] Deng Zhang *Image denoising using pulse coupled neural network with an adaptive Pareto genetic algorithm* Copyright © 2011 Institute of Electrical Engineers of Japan DOI: 10.1002/tee.20684 2011

Referencias en línea

- [Esaa, 2010] Esaa Raitza, Perez Lorena, Acosta Carlos, Duran Carlos, Medina Angel y Rodriguez Alfredo, ”Taller de Redes Neuronales”, <<http://gruporedesneuronales.wordpress.com/2010/05/>>, 2010, Fecha de consulta : 28 de Marzo de 2013.
- [Marrero, 2007] Marrero Eddie, ”Neurona”, < <http://academic.uprm.edu/eddiem/psic3001/id36.htm> >, Mayagüez, Puerto Rico, 2007, Fecha de consulta: 28 de Marzo de 2013.
- [Corbis corporation, 2002] *Corbis images, Corbis corporation*, disponible en: <http://www.corbisimages.com/>.