

UNIVERSIDAD NACIONAL DE SAN AGUSTÍN
ESCUELA DE POSTGRADO.

UNIDAD DE POSTGRADO DE LA FACULTAD DE
INGENIERIA DE PRODUCCION Y SERVICIOS



RECONOCIMIENTO DE PATRONES MEDIANTE REDES COMPLEJAS

Tesis presentada por el Magister en Ciencias de
Computación y Matemática Computacional: Juan
Carlos Gutiérrez Cáceres

Para optar el grado de Doctor en Ciencia de la Com-
putación.

Asesor: Dr. César Armando Beltrán Castañón

Octubre-2013

A mi familia por todo el
apoyo dado

Agradecimientos

A **Dios** a mi **familia**, a mis amigos que siempre estuvieron a mi lado.

Carlos

Resumen

La detección de patrones no es una tarea trivial, especialmente cuando se tienen datos heterogéneos aún dentro de un dominio específico. En la literatura existe una diversidad de técnicas para la detección y reconocimiento de patrones, es así que en los últimos años se ha tomado un especial interés en la técnica de redes complejas, las cuales son representadas como grafos con gran cantidad de nodos y patrones de conexión no triviales. Sin embargo, no se conoce el potencial de esta estrategia, ni su aplicación a diversos problemas de reconocimiento de patrones, especialmente si tendrá un comportamiento óptimo para ciertos dominios. En ese sentido, el presente trabajo propone un modelo basado en redes complejas para el reconocimiento de patrones, el cual ha sido aplicado exitosamente para el reconocimiento de series temporales y de imágenes digitales. El modelo propuesto lleva a una representación de grafo mediante un algoritmo de transformación, aplicado a series temporales, tomando en consideración el total de la información, lo cual la diferencia de otras técnicas que extraen sólo parte de la misma. Para el caso de imágenes, en la literatura se tiene antecedentes del uso separado de la representación de contorno y del contenido de los objetos en análisis. Nuestro trabajo propone una representación conjunta del contorno y el contenido. Como primer caso de estudio, se realizaron experimentos con un conjunto de secuencias de sonido de vocablos, con el objeto de desarrollar un reconocimiento de habla, siendo que nuestra propuesta consiguió reconocer el 99.44% los diferentes vocablos probados. Para el reconocimiento de patrones, se experimentó con imágenes de la base de datos de parásitos de Helmintos, siendo que el mismo está constituido por 11 especies diferentes con una base de datos de 1036 imágenes, donde nuestra propuesta consiguió el 98.74% de acierto. Estos resultados son muy superiores a los conseguidos por técnicas tradicionales, lo cual nos indica que el uso de redes complejas para el reconocimiento de patrones es una técnica muy promisoría, y con el presente trabajo se contribuye a enriquecer no solo la literatura en el área, sino en la solución de aplicaciones prácticas como las experimentadas..

Abstract

The detection of patterns is not a trivial task, especially when data are heterogeneous even within a specific domain. In the literature there are a variety of techniques for the detection and pattern recognition, so that in the last years there is particular interest in the complex networks technic, which are represented as a graph with nodes and large quantity of patterns nontrivial connection. However, is not known the potential of this strategy nor its application to various pattern recognition problems, especially if it will have an optimum performance for certain domains. In that sense, this thesis proposes a model based on complex networks for pattern recognition, which has been successfully applied to time series recognition and digital imaging. The proposed model leads to graph representation by a transformation algorithm, applied to time series, taking into consideration all information, which differentiates from other techniques that using extracted only part of it. For the case of images, in the literature has a antecedent of use separately from the contour representation and content analysis of the objects . Our work proposes a joint representation of the contour and content analysis. As a first case study, experiments were tested with a set of sound sequences of words, in order to develop a speech recognition, being that our proposal achieved 99.44 % of recognize the different words tested. For pattern recognition, experimented with images database Helminth parasites, being that consists of 11 different species with a database of 1036 images, where our proposal achieved 98.74 % success rate. These results are much higher than those achieved by traditional techniques, which indicates that the use of complex networks for pattern recognition is a very promising technique, and the present work not only enriches the literature, but in solving practical applications as experienced.

Índice

1	Introducción	1
1.1	Contexto y motivación	1
1.2	Definición del problema	3
1.3	Objetivos	4
1.3.1	Objetivos específicos	4
1.4	Estructura del documento	4
2	Redes complejas	6
2.1	Consideraciones iniciales	6
2.2	Sistemas complejos	7
2.3	Red compleja	7
2.4	Grafos	11
2.5	Estructura de las redes complejas	12
2.6	Modelos de las redes complejas	13
2.6.1	Redes aleatorias	14
2.6.2	Redes mundo pequeño	15
2.6.3	Redes libre de escalas	15
2.7	Medidas	16
2.7.1	Medidas relacionadas a la distancia	16
2.7.2	Medidas relacionadas al agrupamiento y búsqueda de ciclos	18
2.7.3	Grado de distribución	19
2.7.4	Medidas de centralidad	20
2.8	Consideraciones Finales	20
3	Reconocimiento de patrones y redes complejas	21
3.1	Consideraciones iniciales	21
3.2	Series temporales y redes complejas	22
3.2.1	Series temporales	23
3.2.2	Técnicas estadísticas para las series temporales	23
3.2.3	Análisis de series temporales	25
3.2.4	Análisis de series temporales mediante representación por redes complejas	25
3.2.5	Problemática actual en la representación de las señales	28

3.3	Imágenes y redes complejas	28
3.3.1	Textura de una imagen	29
3.3.2	Clasificación de texturas	30
3.3.3	Representación de texturas mediante redes complejas (Wesley, 2010) (Backes, 2010)	30
3.3.4	Contornos de una imagen	31
3.3.5	Métodos para detección de contornos	32
3.3.6	Creación de red compleja a partir de contornos	32
3.3.7	Situación actual y problemática en la representación de imágenes . . .	33
3.4	Consideraciones finales	34
4	Método propuesto	35
4.1	Consideraciones iniciales	35
4.2	Esquema general de la propuesta	35
4.3	Propuesta para caracterizar series temporales mediante red compleja	37
4.3.1	Representación de la serie temporal por red compleja	38
4.3.2	Obtención del vector de características	41
4.4	Propuesta para la caracterización imágenes mediante redes complejas	43
4.4.1	Representación de la imagen por red compleja	43
4.4.2	Obtención del vector de características	46
4.5	Clasificador	47
4.5.1	<i>Canonical discriminant analysis (CDA)</i>	48
4.5.2	Maquinas de vectores soporte (MVS)	49
4.6	Validación cruzada	52
4.7	Consideraciones finales	53
5	Resultados experimentales	54
5.1	Resultados de la aplicación para el reconocimiento de palabras	54
5.1.1	Adquisición, Cuantificación y Muestreo	56
5.1.2	Detección de inicio y fin	57
5.1.3	Extracción de características	58
5.1.4	Clasificación de las palabras habladas	58
5.2	Reconocimiento de parásitos helmintos	61
5.2.1	Conjunto de datos	63
5.2.2	Técnicas de extracción de características	67
5.2.3	Redes complejas para la clasificación de parásitos	74
5.2.4	Red compleja del modelo propuesto	75
5.2.5	Clasificación de parásitos	76
6	Conclusiones	85
6.1	Discusión sobre el modelos propuesto	85
6.2	Conclusiones	86
6.3	Recomendaciones	87
6.4	Trabajos Futuros	88
	Referencias Bibliográficas	88

Lista de Figuras

2.1	Red de amigos de un colegio en los Estados Unidos: Dos personas están conectadas si son amigos.Fuente: (Newman, 2003).	8
2.2	Red de contagios entre personas: Dos personas están conectadas si una contagió de una enfermedad a la otra. Fuente:(http://www.orgnet.com).	9
2.3	Red de contactos sexuales entre individuos: Dos personas están conectadas si han tenido por lo menos una relación sexual.Fuente: (Keeling and Eames, 2005).	9
2.4	Red de proteínas: Dos proteínas están conectadas si participan en la misma reacción química. Fuente: (Hidalgo, 2010)	10
2.5	Internet: Dos computadoras están conectadas si hay un cable que las conecta.Fuente: (Watts and Strogatz, 1998b).	10
2.6	Documentos en un sitio Web: Dos páginas web están conectadas si hay un hipervínculo de una a la otra.Fuente: (Newman, 2003).	11
2.7	Red regular cada nodo tiene el mismo numero de conexiones	14
2.8	(a)Grafo aleatorio de Red Erdos y Renyi (b) distribución de los grados	14
2.9	Transición entre red aleatoria a red regular donde el caso intermedio es una red de con características de pequeño mundo	15
2.10	(a)Red libre de escala (b) Distribución de colectividad de los nodos	16
3.1	representación de una imagen mediante una malla regular conectada con los 8 vecinos (Wesley, 2010).	30
3.2	Creación de diferentes redes a partir de la malla regular (Wesley, 2010).	31
3.3	Creación de diferentes redes a partir del contorno de una imagen.	33
4.1	Esquema general de la propuesta de reconocimiento de patrones mediante redes complejas.	36
4.2	Ejemplos de serie temporal correspondiente a la palabra uno.	39
4.3	Ejemplos de serie temporal correspondiente a la palabra dos.	39
4.4	Ejemplos de redes complejas para diferentes valores de θ en la figura (a) el valore de $\theta = 1$, (b) el valor de $\theta = 5$, (c) el valor de $\theta = 10$, (d) el valor de $\theta = 15$	40
4.5	Imagen como una superficie 3D en diferentes ángulos.	44
4.6	Representación de los vertices de una imagen del cerebro.	45
4.7	Efecto de diferentes umbrales para establecer las aristas.	46

4.8	Representación de diferentes texturas, se puede apreciar que las redes son diferentes, manteniéndose las diferencias entre las cuatro texturas diferentes	47
4.9	Caso linealmente separable	50
4.10	Caso no linealmente separable	51
5.1	Gráfica de las amplitudes de las palabras grabadas: En la figura(a) son nueve palabras diferentes; el numero Uno, Dos, Tres, Cuatro, Cinco, Seis, Siete, Ocho y Nueve; En la figura (b) Muestras de una misma palabra pueden ser vistas . .	55
5.2	Determinación de ventanas solapadas para la detección del inicio y fin de palabra	56
5.3	Determinación de ventanas solapadas para la detección del inicio y fin de palabra	57
5.4	Redes construidas para diferentes distancias	59
5.5	Relación entre las diferentes variables canónicas	60
5.6	Imágenes de la base de datos SADPI8 v2.0	64
5.7	Nombres de parásitos: 1) Ascaris 2) Uncinarias 3) Trichuris trichuria 4) Hymenolepis nana 5) Dyphillobothrium pacificum 6) Taenia solium 7) Fasciola hepática 8) Enterobius vermicularis	65
5.8	Muestra de imágenes de diferentes parasitos de la base de datos usada para la clasificación de parásitos	68
5.9	Propuesta para la clasificación de los parásitos Helmintos	79
5.10	Contornos externos e internos de los diferentes parásitos	80
5.11	Imagen micrográfica del parásito también se puede ver su visualización en 3D, y dos redes generadas para dos parametros distintos cuando la distancia vale 4 y cuando vale 6	81
5.12	Enterobius Vermiculares con problemas de transformaciones geométricas, se puede ver que su vector de características para las diferentes transformaciones geométricas son muy parecidas eso hace al método robusto ante problemas de rotación y escala, (a) Reducida de tamaño al 50% del tamaño original, (b) Imagen Original, (c) Aumentada de tamaño al 150 %, (d) Imagen rotada y aumentada 150 %, (e) Imagen normal rotada, (f) Imagen rotada y disminuida de tamaño	82
5.13	Análisis de las variables canónicas se pueden ver la combinación de la 8va variable combinada con la 7ma, 6ta, 5ta, 4ta, 3ra, 2da, 1ra. Y 3ra combinada con las variables 2da, 1ra	83
5.14	Visualización de la variable 7ma con la 6ta, 5ta, 4ta, 2da, 1ra variable. También vemos la 4ta y 3ra, 2da, 1ra. Además la 6ta combinada con 5ta, 4ta, 2da, 1ra finalmente la 5ta variable combinada con 4ta, 3ra, 2da, 1ra	84

Lista de Tablas

5.1	Comparación de los resultados para diferentes parámetros del modelo propuesto.	61
5.2	Matriz de confusion, cons sus respectivos error por cada clase, usando SVM con kernel lineal.	62
5.3	Matriz de confusion, cons sus respectivos error por cada clase, usando SVM con kernel polinomial.	62
5.4	Cantidad de micrografías por especie y parásitos segmentados encontrados en las micrografías	65
5.5	Comparación de los resultados para diferentes parámetros del modelo propuesto.	77
5.6	Comparación de los resultados para diferentes parámetros del modelo propuesto.	77
5.7	Matriz de confusion, con sus respectivos error por cada clase de la clasificación del método propuesto a los 8 especies de parásitos helmintos.	78
5.8	Matriz de confusion, cons sus respectivos error por cada clase, para el modelo basado en contornos.	80

Introducción

1.1 Contexto y motivación

En la actualidad podemos apreciar diferentes tecnologías emergentes que nos ayudan a resolver problemas reales, muchas de estas tecnologías son fruto de las denominadas ciencias complejas, donde técnicas como la teoría del caos, redes complejas son utilizadas como una nueva alternativa de solución a muchos problemas tradicionales e incluso en ingeniería (Costa et al., 2007).

Una de estas tecnologías que esta tomando mucha importancia es el campo de las redes complejas. Este area de investigación surge inicialmente por el interés de entender a las diferentes redes que existen en la naturaleza, por ejemplo el cerebro está compuesto de más de cien mil millones de neuronas, se dice que cada neurona tiene entre diez mil a quince mil conexiones (sinapsis), eso quiere decir que tenemos billones de sinapsis, es por ese motivo que el cerebro es uno de las redes complejas mas representativas. Existen diferentes estudios han venido siendo desarrollados sobre el cerebro, ya que en él se llevan a cabo una serie de actividades neuronales y procesos cognitivos complejos, que el ser humano aun no consigue descifrar del todo (Boccaletti et al., 2006). Trabajos como el de Rubinov (Rubinov and Sporns, 2010) analiza el nivel de conectividad del cerebro como una red compleja, mediante el uso de diferentes métricas las cuales son muy usadas en el análisis de las redes en general.

Existen muchos fenómenos en la naturaleza que también pueden ser modelados como redes complejas, como por ejemplo: las redes biológicas (los enlaces de las proteínas), las redes de comunicación física como internet, las redes sociales, las redes epidemiológicas, las redes ecológicas, las redes de distribución eléctrica (Pagani and Aiello, 2013) etc; las redes se encuentran en todas partes. Es por ese motivo que estudiar las redes complejas se ha convertido un área de investigación activa, el cual esta inspirado por el análisis empírico de las redes del mundo real (Ravasz and Barabási, 2003).

Al inicio, el estudio de las redes complejas estuvo encomendado principalmente a físicos e estadísticos, pero fueron necesarios modelos matemáticos y otras herramientas más poderosas, para poder entender y explicar las propiedades estructurales y dinámicas de las redes, y así se fueron incrementandose otras áreas de investigación entre ellas: medicina, economía, biología, y ahora la ciencia de la computación (Reijneveld et al., 2007), la cual permite implementar herramientas para poder simular y realizar experimentos sobre diferentes modelos propuestos

Las redes en general poseen diferentes tamaños y complejidades y también tienen propiedades de similares en su estructura, las que pueden ser modelados desde un contexto de teoría de grafos, siendo representados en términos de nodos y aristas (conexiones entre nodos), con características topológicas no triviales, es decir, donde la distribución de sus conexiones no son ni regulares puros ni aleatorios (Boccaletti et al., 2006).

Hoy en día esta área de investigación está ayudando a resolver diferentes problemas, por ejemplo en la representación de redes sociales tenemos el trabajo de (Marina and Carlos, 2010) donde se modela la red social Twitter y se analiza su estructura y algunas propiedades de dicha red, en el procesamiento de lenguaje (Pardo et al., 2006) lo uso para evaluar la calidad de redacción de textos, en (Amancio et al., 2012) se usan las redes complejas para resumir textos, también en el reconocimiento de patrones vemos que existen trabajos para modelar las series temporales en grafos de tal manera que la dinámica de los sistemas pueden ser analizados desde el punto de vista topológico, como lo hizo (Zhang and Small, 2006) el cual modelo los sistemas dinámicos en redes complejas usando la correlación, otro trabajo modelo la actividad sísmica de diferentes lugares de la tierra (Davidsen et al., 2005) (Ferreira et al., 2013).

Muchos han propuestos diferentes métodos de construcción de redes complejas a partir de series temporales, trabajos como el de (Dellnitz et al., 2006) el cual está basado en la partición del espacio de fase de un sistema dinámico en k conjuntos disjuntos, transformando las trayectorias en una secuencia de nodos usados para detectar las diferentes transiciones que una serie temporal pueda tener, puesto que las series temporales reales pueden tener ruido entonces él usa un umbral para poder realizar las particiones del espacio. También tenemos el trabajo de (Zhang et al., 2008) que propuso modelar la red mediante el coeficiente de correlación en búsqueda de ciclos pseudo periódicos. Otro trabajo muy usado es el de (Lacasa et al., 2008) que mediante

el concepto de visibilidad de estados crea la red compleja a partir de una serie temporal. Como se pudo apreciar muchos trabajos están siendo desarrollados para estudiar las series temporales desde el enfoque de redes complejas.

Las redes complejas también vienen siendo usadas para caracterizar imágenes de tal manera que esta pueden detectar e identificar objetos dentro de las mismas, el trabajo que propone (Fabricio, 2010) muestran aplicaciones en segmentación de imágenes, otros trabajos también han sido desarrollados para poder como el de (Backes et al., 2010) que muestra el uso de la textura para modelar una red y luego caracterizarla. También existen trabajos en los cuales la forma de los objetos contenidos en una imagen son el punto principal para modelar la red como lo muestra el trabajo de (Backes et al., 2009) el cual lo uso para clasificar hojas por su forma.

1.2 Definición del problema

El problema principal es representar un patron mediante una red compleja para posteriormente caracterizarla y reconocerla, cuando quiere trabajar en esta area se tiene que considerar el tipo de patron a tratar, ya que de una buena representación dependerá el éxito del reconocimiento, el problema se complica desde el momento que se quiere trabajar con patrones de series temporales (1D) e imágenes (2D). En ese sentido el modelo propuesto debe ser robusto ante estos dos tipos de patrones.

En la actualidad existe muchas técnicas para modelamiento de redes complejas a partir de series temporales, pero están principalmente orientadas a mantener ciertas propiedades de su dinámica, mas no son propuestas para ser usadas en el reconocimiento de las mismas. Dichas propuestas tienen diferentes problemas como: pérdida significativa de información, mientras que otros son orientados a series específicas como series pseudo aleatorias, por otro lados existen métodos donde se busca una correlación de un segmento de ciclo que se esté repitiendo en la señal, donde el problema principal es la dimensión del ciclo que se busca, otras técnicas construyen redes según el grado de visibilidad entre los diferentes estados confundiendo series determinísticas con series aleatorias.

Por otro lado cuando se quiere trabajar con imágenes, se necesita que el modelo mantenga las propiedades que las imágenes, por ejemplo caracterizar la forma de los objetos así como la textura que posee en un solo modelo ya que existen básicamente tendencias de varios autores que usan las propiedades por separado, hay modelos orientados solo a la representación de la forma de los objetos no tomando en cuenta la textura de la imagen, y también existen modelos que solo usan la propiedad de la textura dejando de lado la forma en ese sentido pierden información inherente a la imagen por tratar por separado dichas características.

En el capítulo 3 se presentara mayor detalle de las técnicas existentes tanto para series temporales como para imágenes analizando detalladamente las ventajas y limitaciones de cada propuesta.

1.3 Objetivos

El objetivo general de esta tesis es proponer un nuevo modelo de representación de red compleja para el reconocimiento de patrones, específicamente para reconocimiento de palabras (1D) y reconocimiento de imágenes (2D).

1.3.1 Objetivos específicos

- Proponer una forma de modelamiento de red compleja a partir de series temporales;
- Proponer un modelo de representación de red compleja a partir de imágenes;
- Seleccionar las medidas más adecuadas para las redes complejas creadas;
- Probar las técnicas en reconocimiento de palabras y en el reconocimiento de imágenes de parásitos helmintos.

1.4 Estructura del documento

Este documento esta estructurado de a siguiente manera:

- En el capítulo 2 se presentan los conceptos básicos referentes a las redes complejas, donde la teoría de grafos es una parte importante además de las medidas mas usadas serán descritas
- En el capítulo 3 describiremos el estado del de las técnicas para modelar redes complejas a partir de series temporales, comparando y analizando las ventajas y desventajas de los modelos existentes, de igual manera se hará con los modelos existentes en el reconocimiento de imágenes, analizando las limitaciones de los modelos actuales existentes.
- En el capítulo 4 se explicara la propuesta para el reconocimiento de patrones mediante redes complejas, acá se presentara el modelo propuesto y las ventajas que tiene con respecto a otros modelos.

- En el capítulo 5 Las pruebas y resultados de ambos casos de estudio serán presentadas analizando las ventajas de las propuestas
- Finalmente las conclusiones, recomendaciones y trabajos futuros serán presentados

Redes complejas

2.1 Consideraciones iniciales

Definir una red compleja no es sencillo, ya que por ser un campo emergente de investigación es que esta intentando ordenarse según las diferentes investigaciones que se vienen realizando actualmente no existe una definición formal ya que redes complejas están presentes en diferentes áreas de investigación. Muchos fenómenos de la naturaleza se puede modelar como una red, como las estructuras del cerebro, la proteína-proteína redes de interacción, las interacciones sociales y el Internet y la WWW. Todos estos sistemas pueden ser representados en términos de nodos y aristas que indican las conexiones entre los nodos. En Internet, por ejemplo, los nodos representan los routers y las aristas representan las conexiones físicas entre ellos. De la misma manera, en las redes de transporte, los nodos pueden representar a las ciudades y las aristas representan las carreteras que los conectan. Estas aristas pueden tener pesos, que puede representar el flujo de tráfico en una autopista o una frecuencia en el caso de palabras pueden corresponder a la ocurrencia dos palabras en un texto.

Una característica importante de estas redes es que no son aleatorias, pero tienen una arquitectura estructurada. Todo eso se puede apreciar en la topología ya que son diferentes topologías, por ejemplo las redes de interacción de proteína a proteína e de Internet, son parecidas: siguen la ley de potencia, exhibiendo una estructura libre de escala. Por lo tanto, una cuestión importante se plantea: ¿Cómo pueden los sistemas fundamentalmente diferentes como

las células y el Internet tener las mismas características topológicas subyacentes?. Encontrar las leyes fundamentales que generan estas redes seria la respuesta a esta pregunta, por ese motivo el modelado y la caracterización de ellos son los desafíos actuales en la investigación de redes complejas.

2.2 Sistemas complejos

Como ocurre con gran parte de estudios científicos, no se puede definir los sistemas complejos en un sólo enunciado, a continuación se enumeran las características, que para (Aldana and Cluzel, 2003) son las más importantes:

- Los Sistemas Complejos, son sistemas que están compuestos por muchos elementos no idénticos, conectados bajo diversas interacciones entre si.
- La complejidad se les atribuye a estos sistemas por que poseen propiedades no esperadas, ya que presentan comportamientos emergentes, es decir, que emergen de las interacciones de las partes del sistema.
- Cada parte tiene su propia estructura interna y cada uno tiene una función específica, por ello para describir un sistema complejo hace falta no solo conocer el funcionamiento de las partes sino conocer como se relacionan entre sí. Examinar una única neurona no es suficiente para describir el cerebro.
- Lo que ocurra a una parte del sistema afecta de manera altamente no lineal a todo el sistema. Ejemplos de sistemas complejos son los seres vivos y las sociedades.

2.3 Red compleja

Diversos sistemas están estructurados como elementos que se interrelacionan entre sí (Barabasi and Crandall, 2003). Existen muchos sistemas físicos que son un ejemplo claro de estos elementos interrelacionados como internet, la red física mas grande del mundo. Este tipo de redes hoy en día son ampliamente estudiados todo dado que el estudio de esta interacción puede encontrar comportamiento peculiares (Albert et al., 2000). El estudio de estas redes complejas se enmarca dentro de los sistemas complejos.

Para poder entender una red compleja es importante recordar algunos conceptos sobre teoría de grafos, es por ese motivo que en la siguiente sección se presentaran algunos conceptos necesarios sobre grafos para poder caracterizar a estas redes. A lo largo del presente trabajo, se han

mencionado diferentes ejemplos de redes complejas a continuación comentaremos algo sobre dichas redes las cuales se podrán ver en las siguientes figuras:

En la figura 2.1 se puede apreciar la red de amigos de un colegio en los Estados Unidos donde 2 personas están conectadas si son amigos, puesto que esta red se armo preguntando a los participantes si determinada persona es o no su amigo este podría responder que si mientras que podría no ocurrir de forma inversa, ya que el otro participante podría decir que no lo es por ese motivo este grafo es dirigido, los colores de los nodos representan las distintas razas que existen entre los participantes, y la division entre la parte superior e inferior es realizada entre colegio primario y secundarios (Newman, 2003).




Figura 2.1: Red de amigos de un colegio en los Estados Unidos: Dos personas están conectadas si son amigos.Fuente: (Newman, 2003).

Funcionarios de salud pública realizan el seguimiento de contactos para trazar la propagación de enfermedades infecciosas. La red que muestra en la figura 2.2 muestra la propagación de una enfermedad infecciosa en el aire. El mapa fue creado a partir de datos reales de contacto de la comunidad en la que el brote estaba sucediendo. Los nodos negros son personas con la enfermedad clínica (y son potencialmente infecciosos), los nodos de color rosa representan a las

personas expuestas con la incubación de la infección y no son contagiosas, verde representan las personas expuestas sin infección y no son contagiosas. Como se pudo apreciar es importante el mapeo de una infección para poder realizar estudios de como una infección se propaga.




Figura 2.2: Red de contagios entre personas: Dos personas están conectadas si una contagió de una enfermedad a la otra. Fuente:(<http://www.orgnet.com>).

De forma similar se pueden apreciar otros aspectos por ejemplo en la figura 2.3 en la cual se puede apreciar los contactos sexuales entre personas este grafo fue generado de información registrada de pacientes con VIH, donde una conexión significa que por lo menos esas dos personas tuvieron una relación sexual también se puede apreciar que existen nodos que son lo que tienen mas conexiones siendo uno de ellos focos infecciosos.




Figura 2.3: Red de contactos sexuales entre individuos: Dos personas están conectadas si han tenido por lo menos una relación sexual.Fuente: (Keeling and Eames, 2005).

Para cualquier compleja red es importante saber las propiedades de dicha red, y como es que estas se generan, esos modelos se han usado para mapear la interacción de las proteínas que

conforman la levadura *Saccharomyces cerevisiae*. A nivel biológico también se pueden tener redes como la que se aprecia en la figura 2.4 donde dos proteínas están conectadas si participan de la misma reacción química.




Figura 2.4: Red de proteínas: Dos proteínas están conectadas si participan en la misma reacción química. Fuente: (Hidalgo, 2010)

El ejemplo de red mas grande es de internet donde se puede ver como las computadoras pueden estar conectadas físicamente mediante un cable en la figura 2.5 podemos apreciar la conexión física de Internet.




Figura 2.5: Internet: Dos computadoras están conectadas si hay un cable que las conecta. Fuente: (Watts and Strogatz, 1998b).

En la figura 2.6 podemos ver las interconexiones de los hipervínculos entre páginas web, dos páginas están conectadas si existe un hipervínculo que los une.




Figura 2.6: Documentos en un sitio Web: Dos páginas web están conectadas si hay un hipervínculo de una a la otra. Fuente: (Newman, 2003).

Como se pudo apreciar existen muchos trabajos en los cuales las redes complejas aparecen como ejemplo de modelamiento, ya sea de fenómenos sociales, como biológicos, e incluso de como el ser humano extendió sus redes en esta gran red denominada internet.

Para poder formalizar los diferentes conceptos de las redes complejas es necesario apoyarse en conceptos matemáticos por ese motivo es que a continuación describiremos algo de la teoría de grafos ya que es la indicada para poder expresar de manera formal los conceptos sobre la teoría de grafos.

2.4 Grafos

Las redes complejas en este contexto son representados por conjuntos de nodos denominados vértices los cuales están conectados, esta conexión representa la interacción que se tiene entre nodos los cuales son denominados aristas.

Un grafo $G = (V, E)$ es un objeto abstracto formado por el conjunto de vértices V (nodos) y el conjunto E de aristas (enlaces) que se unen (de conexión) en pares de vértices. El conjunto de vértices y un conjunto aristas de un grafo G se denota por $V(G)$ y $E(G)$, respectivamente. La cardinalidad de V por lo general, se denota por n , y la cardinalidad de E se denota por m . Si dos vértices están unidos por una arista ellos son llamados de adyacentes o también pueden ser denominados como vecinos. Los Grafos pueden ser no dirigidos o dirigidos. En los grafos no dirigidos, el orden de los vertices unidos por una arista no tienen un orden en particular la cual es considera como simétrica. Una arista no dirigida uniendo los vértices $u, v \in V$ se denota por $u, v = v, u$. en grafos dirigidos, cada arista dirigida tiene un origen y un destino. Una arista con

origen $u \in V$ y destino $v \in V$ está representada por el par ordenado (u, v) el cual es distinto de (v, u) .

Llamaremos a todos los nodos que estén conectados directamente a un nodo v_i como vecinos de v_i . El número k_i vecinos del nodo v_i (número de conexiones de v_i) se denomina grado de conectividad de v_i .

En lo que corresponde a grafos existe el denominado grafo regular, el cual es aquel que en todos los nodos tiene un mismo grado de conectividad, así un grafo irregular es aquel que posee nodos con diferentes grados de conectividad. Un grafo altamente irregular es caracterizado por el hecho de que cada uno de sus vértices o nodos es adyacente a vértices de grados diferentes entre sí.

En ese sentido las redes complejas son definidas como redes cuyos vértices pueden presentar diferentes grados entre si. Nótese que la definición indica que no necesariamente todos los nodos deben estar conectados unos con otros, ni que todos los nodos deben tener conexiones, es decir, pueden existir nodos aislados.

A continuación Franceschi (de Angelis André, 2005) hace hincapié en los siguientes algunos puntos que son tomados en consideración para decir si una red es compleja o no, el tamaño de la red no será determinante para la clasificación de la red en regular o compleja. En las redes complejas no es prevista la existencia de conexiones. Las redes regulares son consideradas casos particulares de redes complejas. Es decir, el conjunto de las redes complejas contiene al subconjunto de las redes regulares. Es por ese motivo que es importante estudiar la estructura de las mismas.

2.5 Estructura de las redes complejas

Dado que la red compleja esta formada de nodos y aristas es que el estudio de su estructura esta relacionado a la interrelación que tienen estos elementos en la red, siendo el interés determinar las propiedades estructurales de la red, estas propiedades se basan en el estudio de las siguientes características:

La distribución de conexiones $P(k)$: Es la probabilidad de que un nodo escogido al azar tenga k conexiones. Por ejemplo, en una red de contactos sexuales $P(k)$ es la probabilidad de que una persona escogida al azar en una sociedad haya tenido k parejas sexuales distintas a lo largo de su vida. El coeficiente de agregación C : Es la probabilidad de que dos nodos conectados directamente a un tercer nodo, estén conectados entre sí. Por ejemplo, en una red de amistades, es la probabilidad de que dos amigos sean ellos mismos amigos uno del otro. La longitud mínima L_{ij} entre dos nodos v_i y v_j : Es el número mínimo de “saltos” que se tienen

que dar para llegar de un nodo v_i de la red a otro nodo v_j de la red. La longitud promedio de la red L : Es el promedio de las longitudes mínimas L_{ij} entre todas las posibles parejas de nodos (v_i, v_j) de la red. La distribución de tamaños de islas $P(s)$: Es la probabilidad de que una isla esté compuesta por s nodos. El tamaño de la isla más grande la que denotaremos por S_∞ . El grado de un vértice es también importante: Aquellos nodos con un grado alto en relación de los demás son llamados hubs, y su presencia en la red tiene una gran influencia en su estructura. Una importante característica de las redes complejas es que no son aleatorias, si no al contrario poseen una arquitectura estructurada.

Para Aldana (Aldana, 2006) el estudio general de las redes puede dividirse en dos campos diferentes: Estructura y Dinámica. En el campo de estructural se está interesado en conocer la distribución de las conexiones o vecinos, el coeficiente de agregación que es la probabilidad de que dos nodos conectados a un tercer nodo, estén conectados entre si, también será posible evaluar la longitud mínima entre dos nodos, longitud promedio, entre otros. Una vez que se sabe de qué manera interactúan los nodos (propiedades estructurales) en la red, se hace necesario estudiar sus propiedades dinámicas, como por ejemplo la propagación.

2.6 Modelos de las redes complejas

Antes de comenzar hablar de los diferentes modelos de redes complejas es importante tomar en consideración a las redes regulares las cuales son uno de los modelos mas conocido de redes, donde los vertices poseen un posición bien definida en el espacio euclidean y la distribución de las aristas son distribuidas entre los vecinos topológicos de cada vértice. En la siguiente figura 2.7 podemos apreciar la topología de una red donde se puede apreciar que cada nodo tiene una cantidad igual de conexiones, sobre la variación o diferencias con las redes regulares es que las otras redes aumentan su complejidad en el estudio de la mismas por eso los siguientes modelos difieren de una red regular en la complejidad de sus conexiones.

Existen varios modelos de redes complejas han sido propuestas algunos de esos modelos son de gran interés es por eso que es importante estudiarlos se pueden diferenciar los siguientes modelos:

1. Redes aleatorias
2. Redes mundo pequeño
3. Topología libre de escala




Figura 2.7: Red regular cada nodo tiene el mismo numero de conexiones

2.6.1 Redes aleatorias

Este tipo de redes fueron Erdos y Renyi (P. and A., 1959) los que propusieron una red de este tipo, donde no existen criterios que privilegien las conexiones, las cuales están dadas por simple probabilidad así la red es caracterizada por el numero de vertices n y la probabilidad de conexión p entre los vertices, con un valor n y la conectividad media fija a la distribución de Poisson, la media de los caminos tienden a valores pequeños como se puede apreciar en la figura 2.8




Figura 2.8: (a) Grafo aleatorio de Red Erdos y Renyi (b) distribución de los grados

Las aplicaciones de este modelo son muy limitadas debido a que pocas redes reales se comportan tal (no son aleatorias), sin embargo existen aproximaciones en la teoría de redes complejas en el campo de las redes sociales (redes de afiliación y grafos bipartitos). Una diferencia clara entre las redes reales y las generadas por este modelo se distinguen en la distribuciones de grado, que en el caso de las generadas por este modelo son poissonianas, mientras que en la realidad tienden a ser más exponenciales. En las redes con distribuciones poissonianas se con-

centra la probabilidad en torno a un valor de k (grado del nodo) y decrece a una razón de $1/k$ cuando se aleja del valor central. En las redes exponenciales no existe un valor preferente y la probabilidad decae a lo largo del espectro de k a medida que éste crece.

2.6.2 Redes mundo pequeño

Watts et al (Watts and Strogatz, 1998a), observaron que en algunas redes del mundo real encontraron caminos cerrados con apenas 3 nodos los cuales son diferentes de la definición de las redes aleatorias. Se observaron que dichas redes estaban altamente “clusterizada” al igual que las redes regulares mientras que la distancia media entre cualquiera de las unidades que la forman es mucho mas pequeña que en una red regular y muy cercana a una red completamente aleatoria, pero hay que recordar que en una red aleatoria la clusterización es muy baja debido precisamente a que no hay un grado de afinidad importante para establecer las conexiones. Y esas eran precisamente las redes que normalmente habían sido consideradas por los físicos para modelizar sistemas dinámicos complejos, o bien redes aleatorias o redes regulares. De esta manera es que se introduce un modelo al que llamaron de “mundo pequeño”, es por ese motivo que se necesita una manera diferente de crear redes para poder representar ese efecto real que tenían ciertas redes, este tipo de redes tenían lo que se conoce como el efecto mundo pequeño dado que a distancia de separación entre vertices crece en un regimen logarítmico. Es por ese motivos que (Watts and Strogatz, 1998b) propusieron un modelo simple para crear redes con características de tener valores bajos entre la distancia entre vertices. La siguiente figura 2.9 muestra la red de mundo pequeño.




Figura 2.9: Transición entre red aleatoria a red regular donde el caso intermedio es una red de con características de pequeño mundo

2.6.3 Redes libre de escalas

Este tipo de redes son aquellas que presentan ciertos nodos que tienen la mayor concentración de conexiones con los demás. (Barabási et al., 2000) propusieron la construcción de un modelo

donde existían ciertos vertices llamados referenciales los cuales tiene la característica de tener la mayor cantidad de conexiones y el resto de vertices se caracterizan por tener pocas conexiones normalmente están conectados con el otro tipo de vertices. En la siguiente figura 2.10 se puede apreciar este tipo de redes:




Figura 2.10: (a) Red libre de escala (b) Distribución de colectividad de los nodos

Es importante notar que existen varios modelos de redes complejas porque ellas presentan características que en cierta forma las hacen una distinta de la otra, estas características son cuantificables (medibles) lo cual es importante para diferenciar un modelo de otro.

2.7 Medidas

Existen varias medidas que pueden ser consideradas en la caracterización de las redes complejas, varias de ellas están relacionadas ya que tienen características similares, por ejemplo tenemos métricas relacionadas a la distancia, relacionadas a la búsqueda ciclos, grado de distribución de nodos y correlación, redes con diferentes tipos de vertices, medidas de centralidad entre otras a continuación presentaremos algunas medidas que son importantes para caracterizar una red.

2.7.1 Medidas relacionadas a la distancia

En diferentes casos es importante caracterizar a la red mediante medidas de distancia entre nodos, por ejemplo en aplicaciones de rutas cortas entre diferentes caminos, o ver grados promedio de distancias de un nodo dado hacia todos los demás, existen algunas medidas que nos ayudan a interpretar a la red en función de sus medidas (Costa et al., 2007).

2.7.1.1 Distancia promedio

Se puede definir una medida de la red calculando el valor medio de d_{ij} , conocida como la distancia geodésica promedio:

$$\ell = \frac{1}{N(N-1)} \sum_{i \neq j} d_{ij} \quad (1)$$

Un problema con esta definición es que diverge si hay vértices no conectados en la red. Para evitar este problema, sólo los pares de vértices conectados se incluyen en la suma. Esto evita la divergencia, pero introduce una distorsión de las redes que tienen pares de vertices no relacionados, ya que para estos casos esta medida mostrará un valor de distancia media bajo y seria un error ya que esto se espera sólo para redes con un alto número de conexiones. Latora y Marchiori (Latora and Marchiori, 2001) propusieron una medida estrechamente relacionado que se llama eficiencia global:

$$E = \frac{1}{N(N-1)} \sum_{i \neq j} \frac{1}{d_{ij}} \quad (2)$$

Esta medida cuantifica la eficiencia de envío de información entre un par de nodos de la red, suponiendo que la eficiencia para el envío de información entre dos vértices i y j es proporcional a la inversa de su distancia. El recíproco de la eficiencia global es la media armónica de las distancias geodésicas:

$$h = \frac{1}{E} \quad (3)$$

La determinación de distancias más cortas en una red sólo es posible con la información global sobre la estructura de la red. La distancia efectiva entre dos vértices en general es mayor que la distancia más corta, y depende del algoritmo utilizado para recorrer la estructura de la red.

2.7.1.2 Vulnerabilidad

En redes como la World Wide Web, Internet, suministro de energía, etc es importante saber que los componentes (vértices o aristas) son cruciales para su mejor funcionamiento. Los vértices críticos de una red son considerados como los principales normalmente vértices con mayor grado, sin embargo, hay situaciones en las que no necesariamente es el más vital para el funcionamiento del sistema. Por ejemplo, todos los vértices de una red en forma de un árbol binario tiene el mismo grado, por lo tanto no hay ningún centro, pero la desconexión de uno de los vértices más cercano a la raíz y la raíz misma tiene un impacto mayor que la de los que cerca de las hojas. Esto sugiere que las redes tienen una propiedad jerárquica, lo que significa que los componentes más cruciales son aquellas en las posiciones más altas en la jerarquía.

Una manera de encontrar los componentes críticos de una red es mediante la búsqueda de los vértices más vulnerables. La vulnerabilidad de un vértice se puede definir como la caída en

el rendimiento cuando el vértice y todos sus aristas se eliminan de la red:

$$V_i = \frac{E - E_i}{E} \quad (4)$$

donde E es la eficiencia global de la red y E_i es la eficiencia después de remover el vértice i . y la medida de vulnerabilidad global de una red estará dada por:

$$V = \max_i V_i \quad (5)$$

2.7.2 Medidas relacionadas al agrupamiento y búsqueda de ciclos

Una de las características del modelo de Erdos-Rényi es que la estructura local de un vértice tiende a ser como un árbol, donde la probabilidad de que existan ciclos en una red depende del tamaño de la misma, entre mas cantidad de nodos mas probabilidad de existencia de ciclos y agrupamientos. Cada vertice pose una cantidad asociada que mide el nivel de conectividad entre sus vecinos el coeficiente es definido por:

$$C_u = \frac{2e_u}{k_u(k_u - 1)} \quad (6)$$

donde e_u representa el numero de conexiones compartidas entre los vecinos del vértice u , el valor de este coeficiente varia entre [01]

2.7.2.1 Coeficiente de agrupamiento

Una forma de caracterizar la presencia de ciclos es a través del coeficiente de agrupamiento. Dos coeficientes de agrupamiento diferentes se utilizan con frecuencia. La primera, también conocida como transitividad (Newman, 2001), se basa en la siguiente definición:

$$C = \frac{3N_{\Delta}}{N_3} \quad (7)$$

donde N_{Δ} es el número de triángulos en la red y N_3 es el numero de conexiones triples. Esto represente el coeficiente de consistencia para medir cuantos conjuntos de tres diferentes conectados son diferentes de un triángulo. Un triángulo es un conjunto de tres vértices con aristas entre cada par de vértices; un triple es un conjunto de tres vértices donde cada vértice se puede llegar el uno del otro (directa o indirectamente), es decir, dos vértices debe estar adyacente a otro vértice (el vértice central).

2.7.2.2 Coeficiente de ciclos

Kim y Kim (Kim and Kim, 2005) definen un coeficiente de ciclo para medir qué tan cíclica es una red. El coeficiente cíclico local de un vértice i se define como la media de la inversa de los tamaños de los más pequeños ciclos formado por vértice i y sus vecinos:

$$\Theta_i = \frac{2}{k_i(k_i - 1)} \sum_{j,k} \frac{1}{S_{ijk}} a_{ij} a_{ik} \quad (8)$$

donde S_{ijk} es el tamaño de la menor ciclo que pasa a través de los vértices i, j, k . Hay que tener en cuenta que si los vértices j y k se conectan, el más pequeño ciclo es un triángulo y $S_{ijk} = 3$. Si no hay ninguna arista que pasa por i, j y k , entonces estos vértices son tipo árbol $S_{ijk} = \infty$. El coeficiente cíclico de una red es el promedio del coeficiente cíclico de todos sus vértices:

$$\Theta = \frac{1}{N} \sum_i \Theta_i \quad (9)$$

2.7.3 Grado de distribución

la característica mas importante de un nodo es su conectividad, donde k_i indica el numero de conexiones establecida entre el vértice i y los demás, los vertices conectado con i son comúnmente llamados vecinos del vértice i normalmente se mide a una red con el promedio de conexiones de sus nodos k_u , y esta dada por:

$$k_u = \frac{1}{N} \sum_{i=1}^N k_i \quad (10)$$

donde N representa el numero de nodos y k_u el promedio de conexiones

2.7.3.1 Distribución de probabilidad del grado

La característica de los nodos de una red es un atributo importante es por ese motivo que a veces es necesario saber cual es el máximo grado de un nodo o el mínimo valor

$$k_{max} = \max k_i \quad (11)$$

2.7.4 Medidas de centralidad

2.7.4.1 Excentricidad

Este tipo de medida es usada para resolver problemas de localización minimizando la máxima distancia entre un nodo y cualquier otro nodo, y esta dado por:

$$e_u = \max\{d(u, v) : v \in V\} \quad (12)$$

2.7.4.2 Centroides

Dado un grafo no dirigido G de n vértices. Para una par de vértices u y v , $g_u(v)$ denota el número de vértices que están más cerca de u a v , que se $g_u(v) = |\{w \in V : d(u, w) < d(v, w)\}|$

2.7.4.3 Cercanía

Puede darse el caso minimizar la suma de las distancias de un vértice $u \in V$ a cualquier otro vértice en un grafo $G = (V, E)$ como $\sum_{v \in V} d(u, v)$

2.8 Consideraciones Finales

La teoría de redes complejas cada día esta avanzando, generalmente nuevas medidas son adicionadas a las ya existentes y las propiedades que estas tienen ayudan a caracterizar de mejor manera las las redes complejas dado que esta pueden representar diferentes patrones como series temporales (señales 1D) e imágenes (señales 2D).

Es importante tener en cuenta que las medidas ayudan a caracterizar a las redes de tal manera que también podrían servir para medir la semejanza entre redes diferentes, para así establecer rasgos similares entre redes que representan a patrones semejantes.

Reconocimiento de patrones y redes complejas

3.1 Consideraciones iniciales

En este capítulo se explicaran las técnicas actuales para el reconocimiento de patrones mediante redes complejas para poder explicar como estos son usados se tomaran dos casos de patrones los cuales son series temporales e imágenes.

Para el caso de series temporales para redes complejas, se hará una comparación entre las técnicas existentes para poder encontrar tanto ventajas como desventajas que estas puedan tener y también se hará lo mismo para las aplicaciones relacionadas a imágenes, en este segundo caso existen pocos trabajos de aplicación de redes complejas al procesamiento de imágenes donde el grupo de investigación del instituto de Física de la Universidad de Sao Paulo Brasil es uno de los principales gestores de aplicaciones en reconocimiento de imágenes mediante el uso de redes complejas, grupo con el cual se pudo interactuar por eso se detallaran los modelos creados por este grupo los cuales muestran la manera de como estas redes pueden ser usadas en la clasificación de imágenes en general.

3.2 Series temporales y redes complejas

Observar la realidad no es mas que la manifestación de eventos que pueden ser complejos e inciertos en el pasar del tiempo, a pesar que estos eventos no siempre son los mismos, ellos tampoco son totalmente diferentes. Existe una semejanza y continuidad en ellas mismas que permite generalizar eventos futuros a partir de eventos pasados. Cuando hablamos de una secuencia de valores observados a lo largo del tiempo, y por tanto ordenados cronológicamente, la denominamos en un sentido amplio serie temporal. Resulta difícil imaginar una rama de la ciencia en la que no aparezcan datos que puedan ser considerados como series temporales. Descubrir conocimiento a partir de series temporales es una de las cosas que el ser humano intenta realizar para conocer mejor las regularidades de las variables observadas, así como la comprensión del fenómeno que utiliza dichas variables. Dicho entendimiento de los diferentes fenómenos pueden ayudarnos a realizar posibles predicciones de dichas series (Box et al., 1976).

Cuando el conocimiento exacto de las leyes que gobiernan un determinado fenómeno es expresado a través de ecuaciones precisas, mediante la formulación de un modelo matemático adecuado es posible poder predecir acontecimientos futuros de dicho evento. Anticipar el comportamiento futuro siempre despertó el interés en las mas diversas areas del conocimiento humano. Por ejemplo en finanzas, predecir un ratio es de vital importancia para un inversionista, o predecir la precipitación es importante para los hidrólogos. Denominamos predicción a la estimación de valores futuros de la variable en función del comportamiento pasado de la serie (Salas and Delleur, 1980).

A veces obtener un modelo exacto de los diferentes fenómenos que deseamos predecir es mas difícil de lo pensado, ya que en casos reales, es casi imposible considerar todas las variables que afectan dicho fenómeno. Lo cual hace no práctico el intentar modelar el fenómeno a partir de las variables inmiscuidas. Sin embargo una alternativa diferente para poder realizar una predicción, consiste en la investigación empírica de la serie temporal de la variable a ser predecida, en búsqueda de la identificación de regularidades presentes en las observaciones de la serie de interés. Entonces el desafío se enfoca en encontrar dichas regularidades las cuales normalmente no son siempre evidentes, al contrario normalmente se encuentran enmascaradas por el ruido en la serie temporal (Franses and Van Dijk, 2000).

Evidentemente aunque el valor futuro de una serie temporal no sea predecible con total exactitud, para que tenga interés su estudio, el resultado tampoco puede ser completamente aleatorio, existiendo alguna regularidad en cuanto a su comportamiento en el tiempo, lo que hará posible su modelado y por ende hasta su predicción. La búsqueda de regularidades y de patrones ha sido siempre una de las tareas básicas de la ciencia, y muchas veces se descubren simetrías que sirven de fundamento para la predicción del comportamiento de los fenómenos,

incluso antes de que se entienda la razón o causa que justifica esa regularidad. Esto ocurre por ejemplo con el sistema periódico de los elementos como lo describió (Chatfield, 2003).

Por lo tanto, si podemos encontrar patrones de regularidad en diferentes secciones de una serie temporal, podremos también describirlas mediante modelos basados en distribuciones de probabilidad. La secuencia ordenada de variables aleatorias $X(t)$ y su distribución de probabilidad asociada, se denomina proceso estocástico. Un proceso estocástico es por tanto el modelo matemático para una serie temporal (Box et al., 1976) que permitirá estudiarla y analizarla.

3.2.1 Series temporales

Una serie Temporal es un conjunto de observaciones ordenadas en el tiempo, que pueden representar la evolución de una variable (económica, física, etc.) a lo largo de él. El objetivo del análisis de una serie temporal es el conocimiento de su patrón de comportamiento, para así prever su evolución futura, suponiendo que las condiciones no variarán.

Dado que no se trata de fenómenos deterministas, sino sujetos a una aleatoriedad, el estudio del comportamiento pasado ayuda a inferir la estructura que permita predecir su comportamiento futuro, pero es necesaria una gran cautela en la previsión debido a la inestabilidad del modelo.

La particular forma de la información disponible de una serie cronológica (se dispone de datos en periodos regulares de tiempo) hace que las técnicas habituales de inferencia estadística no sean válidas para estos casos, ya que nos encontramos ante n muestras de tamaño 1 procedentes de otras tantas poblaciones de características y distribuciones desconocidas (Liao et al., 2005). Por eso formalizar el estudio de dichas series.

3.2.2 Técnicas estadísticas para las series temporales

Se llama Serie de Tiempo a un conjunto de mediciones de cierto fenómeno o experimento registradas secuencialmente en el tiempo. Estas observaciones serán denotadas por (Keogh et al., 2004):

$$\{x(t_1), x(t_2), \dots, x(t_n) = t \in T \subseteq R\} \quad (1)$$

Con $x(t_i)$ el valor de la variable x en el instante t_i . Si $T = Z$ se dice que la serie de tiempo es discreta y si $T = R$ se dice que la serie de tiempo es continua. El primer paso en el análisis de series de tiempo, consiste en graficar la serie. Esto va a permitir detectar las componentes esenciales de la serie.

El gráfico de la serie permitirá detectar (Keogh et al., 2004):

- *Outlier*: Son puntos de la serie que se escapan de lo normal. Un outliers es una observación de la serie que corresponde a un comportamiento anormal del fenómeno (sin incidencias futuras) o a un error de medición. Se debe determinar desde fuera si un punto dado es outlier o no. Si se concluye que lo es, se debe omitir o reemplazar por otro valor antes de analizar la serie. Por ejemplo, en un estudio de la producción diaria en una fábrica.
- *Tendencia*: La tendencia representa el comportamiento predominante de la serie. Esta puede ser definida vagamente como el cambio de la media a lo largo de un periodo.
- *Variación estacional*: La variación estacional representa un movimiento periódico de la serie de tiempo. La duración de la unidad del periodo es generalmente menor que un año. Puede ser un trimestre, un mes o un día, etc. Matemáticamente, podemos decir que la serie representa variación estacional si existe un número s tal que: $x(t) = x(t + ks)$. Las principales fuerzas que causan una variación estacional son las condiciones del tiempo. Todos estos fenómenos presentan un comportamiento estacional (anual, semanal, etc.)
- *Variaciones irregulares*: Los movimientos irregulares (al azar) representan todos los tipos de movimientos de una serie de tiempo que no sea tendencia, variaciones estacionales y fluctuaciones cíclicas.

Un modelo clásico para una serie de tiempo, supone que una serie $x(1), \dots, x(n)$ puede ser expresada como suma o producto de tres componentes: tendencia, estacionalidad y un término de error aleatorio. Existen tres modelos de series de tiempos, que generalmente se aceptan como buenas aproximaciones a las verdaderas relaciones, entre los componentes de los datos observados.

1. *Aditivo*: $X(t) = T(t) + E(t) + A(t)$
2. *Multiplicativo*: $X(t) = T(t)E(t)A(t)$
3. *Mixto*: $X(t) = T(t)E(t) + A(t)$

donde $X(t)$ serie observada en instante t ; $T(t)$ componente de tendencia, $E(t)$ es el componente estacional y $A(t)$ componente aleatoria (accidental). Una suposición usual es que $A(t)$ sea una componente aleatoria o ruido blanco con media cero y varianza constante. Un modelo aditivo (1), es adecuado, por ejemplo, cuando $E(t)$ no depende de otras componentes, como $T(t)$, sí por el contrario la estacionalidad varía con la tendencia, el modelo más adecuado es un modelo multiplicativo (2). Es claro que el modelo multiplicativo puede ser transformado en aditivo tomando logaritmos. El problema que se presenta es modelar adecuadamente las componentes de la serie.

3.2.3 Análisis de series temporales

Normalmente, la mejor forma de comenzar a analizar los datos de una serie temporal es representar las observaciones vs. el tiempo a fin de detectar tendencias, patrones, estacionarios, y outliers. Si la variabilidad de la serie cambia con el tiempo, es conveniente aplicar una transformación a los datos que estabilice la varianza. Se suele utilizar una transformación logarítmica o, en ocasiones, considerar el cambio porcentual de cada observación a la siguiente (en lugar de las propias observaciones).

En el análisis de las series temporales se considera que las observaciones contienen: a) un patrón sistemático, y b) un componente de error aleatorio al que llamaremos ruido. La mayoría de las técnicas tienen como objetivo filtrar dicho ruido.

3.2.4 Análisis de series temporales mediante representación por redes complejas

Para poder realizar una análisis desde el punto de vista de redes complejas primero es necesario modelar las series temporales como redes complejas, existen varias propuestas para dicho modelamiento a continuación se mostraran cada uno de ellos para finalmente presentar las ventajas y desventajas que cada modelo tiene.

Diferentes trabajos vienen analizando y comparando varios métodos trabajos como los de (Zhang, 2007), (Wang, 2011), (Campanharo et al., 2011) esto permite entender la relación que existen entre las propuestas que serán presentadas

3.2.4.1 Redes de transición

El concepto de la dinámica simbólica permite caracterizar las propiedades de un sistema dinámico basado en una partición $S_1, \dots, S_K$ de su espacio de fases en K conjuntos disjuntos, produciendo una transformación de toda trayectoria posible en una secuencia de símbolos abstractos. Formalmente, la correcta aplicación de los conceptos de análisis simbólico de series de tiempo, requieren la existencia de una partición que corresponde a una asignación única de secuencias simbólicas para cada trayectoria del sistema. Se debe tener en cuenta que este requisito es generalmente violados en aplicaciones del mundo real debido a la presencia de ruido, sin embargo, ni siquiera en las particiones de casos ideales (sin ruido) se puede estimar. Sin embargo, las aplicaciones de análisis simbólico de series de tiempo han acaparado el interés considerable en numerosas aplicaciones (Donner et al., 2008) (Donner et al., 2010).

El particionamiento del espacio de fases de un sistema dinámico puede ser utilizado para transformar una serie de tiempo en una representación mediante red compleja. En el caso más simple es posible identificar los diferentes conjuntos S_i como vértices de una red y considerar las probabilidades de transición para caracterizar las aristas estableciendo una probabilidad de transición P_{min} como un threshold a partir del cual se conectaran las aristas.

Esta manera de crear la red tiene una clara desventaja es que cuando existen variaciones pequeñas en las amplitudes de la serie temporal al no superar el threshold P_{min} se pierde la información en consecuencia series con pequeñas variaciones serán representadas como redes similares.

3.2.4.2 Redes de búsqueda de ciclos pseudo periódicos

En 2006, Zhang y pequeños (Zhang et al., 2008) sugirió el estudio de las características topológicas de series de tiempo pseudoperiodicas a través de redes complejas. Esta propuesta considera, los ciclos individuales como vértices de una red no dirigida, y la conectividad de los pares de vértices ha sido establecido por el coeficiente de correlación de los ciclos de diferente longitud o alternatively, considerar la distancia del espacio de fases.

Un punto de la crítico a este método es que la definición de un ciclo no esta presente necesariamente en sistemas oscilatorios complejos. En (Zhang et al., 2008), los autores consideraron principalmente los osciladores no lineales en sus regímenes de fase coherente, sin embargo no es claro cómo podría ser un ciclo definido de oscilaciones fase incoherente, por ejemplo un sistema caótico. Además, no es intuitivamente claro la forma de interpretar las correlaciones de los ciclos, ya que los valores de las medidas correspondientes a la correlación no están exclusivamente determinadas por la proximidad de las partes correspondientes de la trayectoria en el espacio de fase, sino que dependen también de la elección concreta de muestreo. Esto podría dar estimaciones bastante diferentes de coeficientes de correlación entre dos ciclos cercanos.

3.2.4.3 Redes correlacionadas

Una generalización del método anterior propuesto por Zhang pero a diferencia del anteriores que solo se aplica a señales pseudo periódicas este modelo se puede aplicar a series de tiempo sin evidentes componentes oscilatorios Yang y Yang (Yang and Yang, 2008) en este modelo se define una dimensión de inmersión simple sobre una serie de tiempo arbitrario, y cada vértice será representado por la dimensión de inmersión de la serie arbitraria a partir de la cual se puede calcular el coeficiente de correlación de Pearson a partir del cual dos vértices serán conectados si superan un threshold. Una dificultad de este método es determinar cuál es la dimensión de

inmersión mas adecuada para representar la señal en una red compleja dado que no se conoce mucho de la series puesto que es objeto de estudio (Marwan et al., 2009).

3.2.4.4 Redes según su visibilidad entre estados

Esta propuesta a diferencia de las demás considera como vértice a cada valor de la serie temporal, eso quiere decir que se tendrá tantos vértices como valores tenga la serie temporal y conectara dos nodos si estos son visibles entre si, eso quiere decir que entre dos estados no haya un valor mayor al promedio de los dos estados de tal manera que se garantiza la visibilidad entre estados. Esta propuesta tiene como principal desventaja de caracterizar mas las series aleatorias y perder algunas de las propiedades de las series temporales caóticas (Lacasa et al., 2008).

3.2.4.5 Redes formadas por el vecino más cercano

Este método define un numero de k para establecer la relación entre dos nodos por lo tanto lo primero que tiene que realizarse es un agrupamiento donde los vecinos más cercanos a cada estado de la serie temporal, representaran un vértice y dos nodos estarán conectados si ellos están dentro de la vecindad de un grupo k_i , esta aproximación no diferenciara entre redes aleatorias y caóticas dado que ambas aproximan el espacio de fases y la temporalidad no es considerada en la conexión de la misma (Xu et al., 2008).

3.2.4.6 Redes Recurrentes

Otro modelo es propuesto por (Xu et al., 2008) el cual particiona el espacio de estados mediante el uso de un retardo de tiempo dado y dimensión embebida, a continuación, se seleccionan un número fijo de vecinos más cercanos conectar los nodos. Este modelo resalta las propiedades de recurrencia de la serie de tiempo original. Similar a las propuestas a otras propuestas donde se usan representaciones a través de plots de recurrencia. Una variación de esta idea es propuesta por (Hirata et al., 2008) propone también el uso de plots de recurrencia a partir del cual crea una matriz de distancias el cual sera considerado como la matriz de adyacencia además añade pesos siendo este un grafo dirigido.

3.2.4.7 Otros Métodos

Otros métodos para la creación de redes complejas a partir de series temporales son mencionados a continuación

- Otra forma de crear redes complejas fueron propuestas en (Bialonski, 2012) donde analiza diferentes aplicaciones en las cuales se modelan redes complejas, por ejemplo en el análisis de series temporales que son capturadas de diferentes sensores siendo la red modelada en función a la correlación que tengan las series temporales capturadas, se presentan aplicaciones en electroencefalogramas donde cada electrodo es un nodo en la red y la correlación entre la serie temporal para diferentes intervalos de tiempo son usadas para crear los enlaces de tal forma que se pueden tener diferentes redes complejas que pueden ser analizadas.
- Una variación también es propuesta en (Luque et al., 2009) es cual es similar al modelo basado en visibilidad la diferencia que la línea de visión usada es horizontal siendo esta un caso particular del cuarto método.

3.2.5 Problemática actual en la representación de las señales

Para el primer método existe una pérdida significativa de información, dado que existe un particionamiento del espacio de estados, el segundo método es bien definido en sistemas oscilatorios (dado que busca ciclos repetitivos) pero no es muy bien definido para estados no coherentes como el caos, para el tercer método también busca ciclos de forma arbitraria la desventaja es determinar la dimensión de los ciclos que se están buscando, el cuarto caso caracteriza más las series temporales aleatorias, siendo que las caóticas pierden algunas de sus propiedades y finalmente este último método no distinguirá los sistemas determinista de los aleatorios

3.3 Imágenes y redes complejas

Una imagen puede ser definida como una función bi-dimensional $f(x, y)$, donde x e y son coordenadas espaciales, y la amplitud de f en cualquier par de coordenadas se denomina intensidad o nivel de gris de la imagen en el punto. Cuando x , y y los valores de la amplitud de f son todos finitos, cantidades discretas, estaremos ante una imagen digital. El procesamiento de imágenes digitales concierne al uso de la computadora en el procesamiento de imágenes. Note que una imagen digital está compuesta de un número finito de elementos, cada uno de ellos teniendo una particular localización y valor. Esos elementos se llaman elementos pictóricos, elementos unidad de imagen o píxeles.

Diferentemente a los seres humanos, que están limitados a la banda visual del espectro electromagnético (EM), las máquinas de imagen cubren prácticamente todo el espectro EM, desde los rayos gamma hasta las ondas de radio. Pueden trabajar también con imágenes generadas

por fuentes que los humanos no están acostumbrados a asociar con imágenes. Estas fuentes incluyen las imágenes ultrasónicas, la microscopía electrónica y las imágenes generadas por ordenador. En definitiva, el procesamiento de imágenes digitales concierne a un amplio y variado elenco de campos de aplicación. No existe un acuerdo unánime de cuáles son los tópicos que cubre el Procesamiento de Imágenes Digitales y cuáles son sus interrelaciones con otras áreas como Visión por Ordenador o Informática Gráfica.

Desde los años sesenta del siglo pasado, el procesamiento de imágenes digitales se ha convertido gradualmente en una de las áreas de investigación científica más importantes. Sin embargo, como cualquier algoritmo de procesamiento de imágenes requiere una vasta capacidad de procesamiento, su desarrollo limitado ha estado en las manos de unos pocos expertos. Pero con el desarrollo rápido de los ordenadores, muchas personas han ido apuntando su gran interés por el procesamiento de imágenes. El desarrollo del procesamiento de imágenes está siendo acelerado aún más con el rápido avance de las tecnologías relacionadas con la computación en paralelo, la maximizada capacidad de memoria de los chips, y el sistema de visualización en color de alta-resolución.

3.3.1 Textura de una imagen

La textura es un ente visual que describe cierto orden estructural o tendencia en los elementos presentes en una imagen. La figura que se muestra a continuación presenta cuatro tipos de textura y su histograma representativo. Es una región macroscópica estructurada de la imagen que presenta propiedades locales constantes, lentamente variables o aproximadamente periódicas. Este orden local radica en la presencia repetida y no casual de partes Elementales que tienen dimensión similar. Depende de la escala a la que se observa la imagen: la textura de un píxel no está definida, hay que estudiar la vecindad de un grupo de píxeles. Dependiendo del tamaño de vecindad elegido la textura puede ser diferente. Características: uniformidad, densidad, tosquedad, aspereza, regularidad, linealidad, dirección, frecuencia, fase.

Para clasificar la textura se pueden utilizar diferentes técnicas como por ejemplo las redes neuronales (son preferibles del tipo perceptrón multicapas por el elevado número de entradas propias de la clasificación de las imágenes), de forma tal que se identifique la tendencia en las tonalidades de grises presentes en la misma. Ello es, se define un área representativa en la imagen que mejor describa la textura que se pretende clasificar y se utiliza la información de los píxeles que la forman (y cierta región de interés) a la que se le asigna determinada clase que la distinga de otros tipos de textura,

3.3.2 Clasificación de texturas

Para clasificar texturas se pueden usar métodos (Parker, 2010):

- Métodos Estadísticos: La distribución espacial de valores de gris es una calidad que define la textura. Analizando la distribución espacial de los valores de gris, se computan características locales de la textura.
- Métodos Geométricos: Consideran la textura compuesta por primitivas. Intentan describir las primitivas y las reglas que gobiernan la organización espacial.
- Métodos basados en modelos: Se basan en la construcción de un modelo que describe la textura. Se pueden utilizar para reconocer texturas o para sintetizarlas.

En el caso de representación de texturas mediante redes complejas tenemos algunos modelos que presentan ventajas y limitaciones que a continuación se explicara.

3.3.3 Representación de texturas mediante redes complejas (Wesley, 2010) (Backes, 2010)

La descripción de método de representación de la red compleja a partir de una imagen, es a partir de una malla regular, donde los pixels de la imagen corresponden a los nodos de la malla y sus aristas serán los 8 vecinos como puede apreciarse en la siguiente figura 3.3.




Figura 3.1: representación de una imagen mediante una malla regular conectada con los 8 vecinos (Wesley, 2010).

Para generar los diferentes modelos será considerado la distancia entre nodos de la malla regular es decir se debe dar un radio de proximidad permitida para la generación de la red. eso

significa que dos nodos de la red regular estarán conectados si la distancia entre los píxeles no supera el valor del radio pre establecido.

Como segundo paso se tomara en consideración el valor de intensidad de imagen eso quiere decir que la semejanza entre un píxel y otro se verá reflejado en el peso de conexión entre los nodos de la red. Para un caso simple se puede usar simplemente el valor absoluto de la diferencia entre intensidades de los píxeles vecinos (en el grado son representados como dos nodos vecinos) el cual si no supera el umbral establecido la conexión se mantendría en caso contrario esa conexión se rompe en ese sentido el grafo deja de ser regular y comienza a volverse red compleja. Este umbral también ira cambiando generando diferentes modelos de redes complejas




Figura 3.2: Creación de diferentes redes a partir de la malla regular (Wesley, 2010).

3.3.4 Contornos de una imagen

La detección de contorno es parte de un proceso de aislamiento (segmentación), que consiste en la identificación de objetos dentro de una imagen. Como es usual, hay varias posibles definiciones de un contorno, siendo cada una aplicable en distintas circunstancias. Una de las más comunes y generales definiciones es el contorno es simplemente un cambio en el nivel de gris que ocurre en una ubicación específica. Cuanto mayor es el cambio de nivel, más fácil resulta detectar el contorno, pero en el caso ideal cualquier cambio de nivel puede ser visto fácilmente.

Una complicación en la detección de un contorno ocurre debido a la digitalización. Es poco probable que una imagen sea muestreada de manera tal que todos los contornos correspondan exactamente con un pixel del borde. Por lo general, el cambio de nivel puede extenderse sobre varios pixeles. Y cuando eso ocurra la posición actual del contorno se considera como el centro de la rampa que conecta el nivel bajo de gris con el nivel alto. Esta es una rampa sólo en el mundo matemático, dado que después de que la imagen ha sido digitalizada (muestreada), la rampa tiene una apariencia escalonada.

La segunda complicación es el clásico problema del ruido. Debido a una gran cantidad de factores como la intensidad de la luz, el tipo de cámaras y lentes, el movimiento, la temperatura, efectos atmosféricos, polvo y otros; difícilmente dos pixeles que correspondan precisamente al mismo nivel de gris en la escena tengan el mismo nivel en la imagen. El ruido es un efecto aleatorio, y es caracterizado sólo estadísticamente. El resultado del ruido en una imagen es que produce variaciones aleatorias en el nivel de un pixel a otro, y entonces las líneas suaves y rampas de los contornos ideales nunca son encontradas en las imágenes reales.

Por eso usar contornos para modelar redes complejas depende en su mayoría de métodos de segmentación y métodos de detección de contornos.

3.3.5 Métodos para detección de contornos

La forma más simple de detectar un contorno es realizar primero una binarización de la imagen, esta binarización puede ser realizada mediante un *thresholding*, donde ante un valor umbral los valores que excedan este umbral toman el valor de uno y el resto el valor de cero una vez realizada este proceso, el siguiente paso es detectar las discontinuidades eso quiere decir buscar los cambio de valores de 0 a 1 o viceversa de tal manera que se obtiene el contorno de la imagen.

El otro método de buscar discontinuidades es la correlación de la imagen con una máscara. En este procedimiento se realiza el producto de los elementos de la máscara por el valor de gris correspondiente a los pixels de la imagen encerrados por la máscara esta máscara puede ser de diferentes formas normalmente es una máscara de tamaño 3x3 la cual puede representar diferentes tipos de operadores como por ejemplo Roberts, Prewitt y Sobel.

3.3.6 Creación de red compleja a partir de contornos

Como se puede apreciar en la figura la forma de crear la red compleja es a partir de la distancia entre los diferentes puntos del contorno es por ese motivo que es necesario primero extraer el contorno de forma adecuada una vez extraído el contorno se procederá a dar diferentes valores de radios de tal manera que dos nodos estarán conectados si la distancia entre cualquier par de

nodos es menor que cierto valores predefinidos de tal manera que se tendrán varios modelos de redes complejas para los diferentes umbrales dados, cada red creada caracterizara alguna propiedad de la forma de la imagen.




Figura 3.3: Creación de diferentes redes a partir del contorno de una imagen.

3.3.7 Situación actual y problemática en la representación de imágenes

En el caso de las imágenes ya existen algunas propuestas para poder representar una imagen mediante red compleja pero es importante notar que existen algunas deficiencias que se tiene que detallar

- Los métodos actuales de construcción de la red son muy simples generan el grafo basados en distancia dado por un radio predeterminado y analizan las propiedades de la imagen por separado (forma y textura)
- La forma es considerada mediante los contornos creando redes en función a la detección de los mismos pero cuando se detecta un contorno se olvidan aspectos como:
 - Obviar puntos internos de la imagen (Geometría interna)
 - Obvia textura del borde como se comento el borde no es un solo pixel sino generalmente es una gran catidad de pixeles eso indica que un borde puede tener un especie de textura del mismo.
- En cuanto al modelo que se basa en la textura se considera la semejanza de intensidades de niveles de gris entre los pixeles, y esto por el contrario del método anterior:

- Obvia contornos y estructuras internas lo que no es adecuado para una buena representación de una imagen

3.4 Consideraciones finales

Como se puede ver existen diferentes maneras de construir redes complejas a partir de series temporales, cabe resaltar que cada una de ellas tiene ventajas y desventajas en cuanto a su uso en las diferentes aplicaciones que este pueda tener: Para el primer método existe una pérdida significativa de información, El segundo método es bien definido en sistemas oscilatorios pero no es muy bien definido para estados no coherentes caos, para el tercer método la desventaja es determinar la dimensión de los ciclos, el cuarto caso caracteriza mas las series temporales aleatorias, siendo que las caóticas pierden algunas de sus propiedades, finalmente este ultimo método no distinguirá los sistemas determinista de los aleatorios

Los métodos actuales de construcción de la red a partir de imágenes, son muy simples generan el grafo basados en distancia (radio) en función a los contornos se crearan las redes y por medio de la distancia dada por un radio distancia se enlazarán los puntos de la red este método, obvia puntos internos (geometría interna), obvia textura interna y textura del borde, y son dependientes de otros métodos como la detección de contornos. Cuando se usa la textura se crean redes también basados en un radio de distancia solo que se usará el color como el responsable de la conectividad, en ese sentido se obvia los contornos y estructuras internas del objeto a analizar y son dependientes de la calidad de captura de imágenes (intensidades de color bien definidas).

Método propuesto

4.1 Consideraciones iniciales

A continuación se explicaran los modelos propuestos para poder realizar el reconocimiento de patrones, la idea propuesta es genérica, en el sentido de que puede servir para representar patrones unidimensionales como es el caso de las series temporales y bidimensionales para el caso de imágenes donde la misma idea es extendida de forma natural, de tal manera que los patrones pueden ser tratados de la misma forma, no interesando la dimensión a pesar que una serie temporal y una imagen son diferentes en dimensión, ambas corresponden a patrones comunes de nuestro mundo.

4.2 Esquema general de la propuesta

Como se puede ver en la figura 4.1 se tiene un objeto de estudio el cual corresponde al patrón que se quiere reconocer, dado que son dos tipos de patrones que se reconocerán, este patrón puede ser una serie temporal o una imagen, según sea uno u otro patrón es que se tratan por separado, cabe aclararse que el uso de las redes complejas se usa únicamente para obtener el vector de características, donde se ataca principalmente el problema de modelamiento de una

red a partir de un patron para luego usar alguna medida de redes complejas para poder realizar la caracterización de la red en análisis:




Figura 4.1: Esquema general de la propuesta de reconocimiento de patrones mediante redes complejas.

Si el patron fuese una señal temporal la dinámica de la misma es la característica mas importante a conservar, además se debe tener en cuenta la temporalidad de los estados (existe un orden dado por el tiempo). Si el caso fuese de una imagen la creación de la red sigue siendo la misma ya que la diferencia con la serie temporal es que esta señal es de dos dimensiones, cuando uno trata con este tipo de señal la ubicación de un estado depende de dos variables x, y y no solo una como pasaba en el caso de una serie temporal, una imagen representa objetos que quieren ser reconocidos donde normalmente las características que tienen estos objetos están en función de la forma, siendo esta una característica importante para su reconocimiento. Otro aspecto importante es la textura que posee el objeto, porque a pesar de tener objetos de formas semejantes estos pueden tener texturas distintas, en ese sentido es importante tomar en cuenta esta característica al momento de la representación.

La representación de los patrones mediante una red compleja deben tener en cuenta las características que anteriormente se mencionaron, por eso las propuestas toman en cuenta esas características al momento de proponer los modelos respectivos. En la propuesta considera el preprocesamiento tanto para las series temporales como para las imágenes a diferencia de otras técnicas propuestas que necesitan de una cantidad considerable de técnicas distintas de proce-

samiento, las que se usan en el sentido de hacer eficiente el manejo de las mismas, ya que una serie temporal y una imagen normalmente tienen miles de elementos y como los modelos propuestos consideran todos estos elementos es que se hace necesario una reducción de la misma, pero esa reducción debe preservar las propiedades de cada una de las señales en el caso de las imágenes es fácil de entender este aspecto ya que uno puede disminuir el tamaño de una imagen disminuyendo la resolución del mismo, claro que existe un límite que para este caso el cual dependería de la capacidad de memoria que puede soportar el computador pero hoy en día se pueden procesar varias señales sin problemas, este aspecto solo afectaría a señales que tengan una dimensionalidad muy grande.

El primer paso para trabajar con la propuesta es hacer representación de la señal como red compleja para luego caracterizarla red mediante alguna medida de redes complejas que esta red pueda tener, como se presente en el capítulo 2 existen muchas medidas que las redes complejas pueden tener, en ese sentido se probaron métricas que pueden ser usadas para la caracterización adecuada del patrón a reconocer medidas de grado de conectividad de un nodo obteniendo así el vector de características.

Finalmente una vez obtenido el vector de características la etapa final implica el uso de algún clasificador el cual en el caso de la propuesta se usa el *support vector machine*, pero hay que tener en cuenta que al usar las redes complejas normalmente el vector de características tiene una gran dimensionalidad, por eso es necesario hacer uso de técnicas de reducción de la dimensionalidad como es el caso de esta propuesta que usa el *Linear Discriminant Analysis* los detalles de cada una de las etapas se presentarán en las siguientes secciones donde se describirán detalladamente cada una de las etapas.

4.3 Propuesta para caracterizar series temporales mediante red compleja

Es importante notar que ya existen métodos que representan las series temporales como se mencionó en capítulos anteriores por ese motivo es importante mencionar algunos las diferencias a las propuestas anteriores tienen al momento de la representación.

- A diferencia del modelo de redes de transición en el modelo propuesto no habrá particionamiento del espacio de estados, siendo cada valor de la amplitud de la onda el valor utilizado directamente en el modelamiento del grafo
- En los modelos basados en visibilidad la conexión entre un nodo en la posibilidad de trazar una línea directa entre uno u otro estado si hubiese un estado intermedio que ob-

staculice la linea simplemente no existe conexión en caso contrario existiría conexión en ese sentido el modelo propuesto usa la distancia entre estados sin considerar la visibilidad de los mismos.

- En relación a las redes de búsqueda de ciclos pseudo periódicos, la propuesta no busca ciclos usa directamente las amplitudes y la distancia entre ellas para crear la Red
- En los métodos de redes correlacionadas se calculan coeficiente de correlación, nuestra propuesta no calcula ningún tipo de correlación solo usa distancia euclidiana entre su estados.
- En cuanto a las redes formadas por el vecino más cercano podría ser parecido la diferencia principal es que no se restringe a k posibles estados se usa todos los que se encuentren a una distancia dada.

4.3.1 Representación de la serie temporal por red compleja

Como se vio en el capitulo anterior una serie temporal es una secuencia de estados a lo largo del tiempo en la siguiente figura 4.2 se puede apreciar un ejemplo de de serie temporal el cual corresponde una señal de voz correspondiente a la palabra uno, naturalmente uno puede apreciar que es una secuencia de distintos estados donde la variable temporal debería definir la vecindad que tiene un estado con el siguiente estados de la serie, esto es importante ya que el orden en el cual están distribuidos esas secuencias son las que hacen que esa señal corresponda a la palabra uno, si se tuviese otra secuencia de estados (otra serie con otro orden) esta correspondería a otra palabra como se puede apreciar en la figura 4.3 donde se puede apreciar otra distribución de estados, las cuales corresponden a la palabra dos, entonces podemos tener como punto importante de una señal la secuencia de valores de la serie y cuando estos valores toman otro orden y otras amplitudes esta debería corresponder a otro tipo de señal.

El modelo propuesto para construir la red sera el siguiente, sea X el conjunto de valores correspondientes a la serie temporal el cual es un vector de $X[x_1, x_2, \dots, x_i, \dots, x_N]$ donde x_i corresponde al valor de cuantización de la serie temporal, otro valor importante en una serie temporal corresponde a su ubicación temporal, por lo tanto el valor x_1 corresponde a la posición temporal t_1 , siendo que existe un vector de T donde $T[t_1, t_2, \dots, t_i, \dots, t_N]$ de tal manera que se forma un par ordenado (x_i, t_i) , de esta forma cada par ordenado corresponderán a puntos en el espacio de $X \times T$ cada punto corresponderá a la posición de los vertices del grafo de nuestra red compleja donde el grafo es $G(V, A)$ siendo V los vertices formado por el conjunto de puntos de la serie temporal y A las aristas, las cuales se crearan en función a la distancia euclidiana $d(v_i, v_j) = \sqrt{(s_i - s_j)^2 + (t_i - t_j)^2}$ entre un par de vertices, por lo tanto sera necesario definir




Figura 4.2: Ejemplos de serie temporal correspondiente a la palabra uno.




Figura 4.3: Ejemplos de serie temporal correspondiente a la palabra dos.

un valor umbral Θ , el cual esta formado por un conjunto de valores $\Theta[\theta_1, \theta_2, \dots, \theta_i, \dots, \theta_M]$ donde θ_i corresponde a un valor umbral el cual sera usado para crear una arista entre dos vertices del grafo $G(V, A)$ donde cada nodo del grafo calculara la distancia euclidiana con todos los demás nodos de la red, de tal manera que una arista si se cumple que la distancia entre un par de vertices es menor o igual a un valor θ_i , dado que Θ es un conjunto de M valores es que existirán M redes complejas.

En las siguientes figuras 4.4 se pueden ver ejemplos de construcción de redes complejas a partir de un segmento de la serie temporal de la palabra uno, donde pueden observarse 4 figuras correspondientes a 4 valores de θ distintos pudiéndose apreciar como el numero de conexiones entre dos nodos aumenta a medida que el valor de θ aumenta.




Figura 4.4: Ejemplos de redes complejas para diferentes valores de θ en la figura (a) el valor de $\theta = 1$, (b) el valor de $\theta = 5$, (c) el valor de $\theta = 10$, (d) el valor de $\theta = 15$.

Para poder calcular la distintas redes complejas es necesario calcular una matriz D de $N \times N$ entre los diferentes vertices de la red tal manera que:

$$D = \begin{pmatrix} d_{1,1} & d_{1,2} & \dots & d_{1,i} & \dots & d_{1,N} \\ d_{2,1} & d_{2,2} & \dots & d_{2,i} & \dots & d_{2,N} \\ \vdots & \vdots & \ddots & \vdots & \dots & \vdots \\ d_{j,1} & d_{j,2} & \dots & d_{j,i} & \dots & d_{j,N} \\ \vdots & \vdots & \dots & \vdots & \dots & \vdots \\ d_{N,1} & d_{N,2} & \dots & d_{N,i} & \dots & d_{N,N} \end{pmatrix} \quad (1)$$

donde $d_{i,j}$ corresponde a la distancia euclidiana entre un par de vertices, dado que el tamaño de dos series temporales de una misma palabra tienen en general tamaños distintos y los valores de la cuantización son variados para una misma palabra hablada, es que se deberá hacer una normalización en el tamaño de dicha serie, de tal manera que deberán ser colocados en un rango entre valores entre $[0, 1]$ para poder hacer esta normalización se realizara el siguiente calculo:

$$D = \frac{D}{\max_{d_{ij}}} \quad (2)$$

donde $\max_{d_{ij}}$ corresponde al valor máximo de la matriz D de esa manera las distancias quedan normalizadas entre los valores $[0, 1]$, dado que los valores ahora están normalizados el valor del umbral θ tendrá también valores entre $[0, 1]$. Una vez que se tienen los valores normalizados es mas fácil obtener las diferentes redes a partir de las cuales se obtendrá el vector de características.

4.3.2 Obtención del vector de características

El modelo genera varias redes las cuales pueden ser representadas como matrices de adyacencia y sobre las cuales se calcularan los diferentes vectores de características. Para obtener las matrices de adyacencia $A[A_1, A_2, \dots, A_i, \dots, A_M]$ siendo A el conjunto de matrices y A_i una matriz de adyacencia para un determinado umbral, la cual se puede obtener con la siguiente ecuación:

$$A_i = F(D, \theta_i) \quad (3)$$

donde A_i corresponde a la matriz resultante, D es la matriz de distancias, θ es el valor del umbral y la función F y se calcula para cada valor de la matriz de distancias d_{ij} como se puede ver en la siguiente ecuación 4:

$$a_{ij} = F(d_{ij}, \theta_i) = \begin{cases} 1 & \text{si } d_{ij} \leq \theta_i \\ 0 & \text{si } d_{ij} > \theta_i \end{cases} \quad (4)$$

El resultado sera una matriz A_{ij} de valores binarios, donde el valor de uno corresponde un enlace entre el nodo i y el nodo j .

Una vez obtenidas las matrices de adyacencia, el siguiente paso es calcular los valores del vector de características $V[v_1, v_2, \dots, v_i, \dots, v_M]$ donde v_i se calcula usando el grado de un nodo g_i el cual es:

$$g_i = \sum_{j=1}^N a_{ij} \quad (5)$$

siendo g_i el grado del nodo i este es usado para calcular el grado promedio del grafo A_i , de tal forma que el valor cada componente del vector de características v_i es el valor promedio conexiones de la red A_i como se puede ver en la siguiente ecuación 6:

$$v_i = \frac{1}{N} \sum_{i=1}^N g_i \quad (6)$$

Una cosa que es interesante notar es que los valores de la matriz de adyacencia A_1 tienen el valor de 1 para las distancias menores e iguales que θ_1 , siendo que $\theta_1 < \theta_2$, entonces la matriz A_1 esta contenida en la matriz A_2 , este punto es importante ya que calcular una matriz para cada valor de θ_i haría que el proceso sea pesado en el calculo de las matrices de adyacencia, además considerando que las señales de sonido son generalmente de gran dimension lo cual haría que el proceso de obtención de características sea mas pesado aun.

Por ese motivo para poder alivianar el calculo es que se utilizan algunas variables adicionales las cuales ayudaran a aprovechar los cálculos de matrices anteriores para los valores promedios de cada una de las matrices que conforman el vector de características. Dado que los valores de θ_i se deben incrementar es que existe una constante δ_θ que hará que el valor de $\theta_2 = \theta_1 + \delta_\theta$, entonces si el valor de incremento fuese $\delta_\theta = 0.1$ y el valor de $\theta_1 = 0.1$ considerando que el valor de $\theta_M = 1$ siendo este el máximo posible entonces se tentarían 10 valores distintos.

Entonces el modelo usa este valor para multiplicarlo con todos los valores de la matriz de distancias normalizadas obteniéndose un nuevo valor $D' = \lceil M \times D \rceil$ el cual tendrá como máximo valor de M y los posibles valores que esta matriz tendrá numeros enteros entre $[1, M]$, además el tamaño del vector de características es M en ese sentido para poder disminuir el numero de cálculos la nueva matriz de distancias se recorrerá una sola vez y los valores de esta matriz d_{ij} corresponderán a la posición del vector de características de tal manera que se irán acumulando, asi el resultado correspondería ana especie de histograma de la matriz de distancias. Finalmente sobre ese histograma se calculara el valor acumulado siendo el valor de $v'_i = \sum_{j=1}^M v_i$. Por ejemplo si $M = 3$ y tuviésemos la siguiente matriz D' :

$$D' = \begin{pmatrix} 1 & 2 & 3 \\ 3 & 3 & 3 \\ 2 & 2 & 3 \end{pmatrix} \quad (7)$$

Y el vector de características de valores acumulados quedaría como resultado $V = [1, 3, 5]$, de esta manera el tiempo de calculo del vector de características disminuye significativamente y hace factible que el modelo pueda ser aplicado en problemas reales.

Hay que notar que para poder representar una señal en general es importante considerar los estados o valores que componen la señal ya se 1D o dos 2D cada señal tiene sus peculiaridades y valores a resaltar y preservar en ese sentido tanto el modelo para series temporales como para imágenes son parecidos a continuación explicaremos la propuesta para imágenes.

4.4 Propuesta para la caracterización imágenes mediante redes complejas

Una imagen captura diversos aspectos que corresponden a una escena, cuando la imagen capturada corresponde a un objeto de interés, es importante caracterizarlo por ese motivo, para poder representarlo es importante considerar algunos aspectos:

- Considerar la forma: el cual es usado para diferenciar la morfología entre uno u otro objeto, como es el caso de las figuras geométricas.
- Considerar la textura: La imagen de un objeto normalmente es una una composición de las distribuciones de intensidad del color además de otros objetos y cuando estos objetos que los componen y estos son repetitivos, o periódicos, o aleatorios todos estos aspectos se consideran al evaluar una textura.
- Considerar los niveles de intensidad (color): el color es una percepción visual además los objetos normalmente tienen un color que lo caracteriza por eso esta característica tiene que ser considerada.

4.4.1 Representación de la imagen por red compleja

El modelo considerara cada aspecto al momento de representarse como una red, dado que una imagen puede ser representada como una función $f(x, y)$ donde x y y corresponden a las posiciones de los distintos pixels los cuales están distribuidos como una matriz las cuales tienen asociados niveles de intensidad en cada posición x, y en consecuencia una imagen puede ser vista como una superficie en 3D como se puede ver en la siguiente figura 4.5.

En el modelo propuesto, un vértice de la red es el punto $P(x, y, I)$ donde x y y son las posiciones de los diferentes pixels que los componen e I corresponde al nivel de intensidad, y se usara la distancia euclidiana entre los vertices para definir las aristas al igual que en la representación de series temporales, con la diferencia que este tiene un parámetro mas que es la intensidad, en la siguiente figura 4.6 se puede ver la imagen tomográfica de un cerebro, además se puede ver la visualización 3D de la misma y finalmente los vertices que corresponden a las posiciones de cada pixel, se puede notar que esta es una imagen de resolución baja para poder apreciar las posiciones de los vertices continuos es que se muestra en un espacio mayor como se puede apreciar claramente en la figura 4.6:

Para poder determinar las aristas se usara el calculo de la distancia entre cada nodo, para el caso de las imágenes se usara la siguiente ecuación 8:




Figura 4.5: Imagen como una superficie 3D en diferentes ángulos.

$$d_{ij} = \sqrt{\alpha((x_i - x_j)^2 + (y_i - y_j)^2) + \beta(I_i - I_j)^2} \quad (8)$$

donde el valor de α y β corresponden a variables paramétricas que ayudan a dar importancia a ciertos aspectos, por ejemplo si se tienen valores altos para α y bajos para β eso quiere decir que vecindades cercanas de pixeles tienen mayor importancia que la semejanza de los niveles de intensidad y si el fuese el caso contrario los valores de intensidad serían priorizados.

Al igual que el modelo para series temporales se crearan diferentes redes, las cuales se crearan en función a umbrales distintos $\Theta[\theta_1, \theta_1, \dots, \theta_i, \dots, \theta_M]$ generando varias redes en la siguiente figura 4.7 se puede apreciar el efecto que tiene el valor de diferentes umbrales, donde claramente que valores bajos del parámetro de θ_i representan la importancia del contorno del objeto dado que el contorno se considera el limite entre dos regiones y corresponden la division entre uno y otro nivel de intensidad ese efecto se puede apreciar cuando el valor de este parámetro toma el valor 2, 4 y 6. Claramente el método propuesto toma en consideración la forma de los objetos tal como se menciono anteriormente.




Figura 4.6: Representación de los vertices de una imagen del cerebro.

La propuesta también toma en consideración las texturas como se puede ver en la figura 4.8 donde se pueden ver cuatro texturas diferentes y cuatro redes generadas por la propuesta cuando el valor de $\theta = 4$, en la primera textura se puede apreciar una especie de cuadrícula tipo una red y al ver su representación en red este aspecto se mantiene lo que es importante ya que de forma similar sucede con la siguiente textura donde son líneas de distintos niveles de intensidad y como se ve en su representación en red también mantiene dicha propiedad otro ejemplo interesante de ver la textura 4 el cual ya es una matiz de intensidades de gris y en su representación como red esta característica se mantiene. Como se pudo las 4 texturas representan 4 redes diferentes lo cual es importante para la siguiente etapa donde se determinara su vector de características.




Figura 4.7: Efecto de diferentes umbrales para establecer las aristas.

4.4.2 Obtención del vector de características

La determinación del vector de características es igual al usado en la serie temporal en ese sentido se hará un resumen de los diferentes pasos realizados.

- Primero una vez obtenida la matriz de distancias D , es necesario normalizarla de tal manera que ayude a la determinación de los diferentes umbrales que se necesiten la cual es realizada por:

$$D = \frac{D}{\max_{d_{ij}}} \quad (9)$$

- Determinar el valor de incremento δ_θ para así determinar el tamaño del vector M .
- Multiplicar la matriz de distancias normalizada por el tamaño del vector de características $D' = \lceil M \times D \rceil$.
- Calcular el histograma de la nueva matriz de distancias $H = \text{hist}(D')$.




Figura 4.8: Representación de diferentes texturas, se puede apreciar que las redes son diferentes, manteniéndose las diferencias entre las cuatro texturas diferentes .

- Finalmente calcular los valores del vector de características $V[v_1, v_2, \dots, v_i, \dots, v_M]$ a partir los valores acumulados del histograma $H[h_1, h_2, \dots, h_i, \dots, h_M]$ según:

$$v_i = \sum_{i=1}^i h_i \quad (10)$$

4.5 Clasificador

El vector de características resultante del proceso anterior tiene normalmente una alta dimensionalidad, por ese motivo se debe usar alguna técnica de reducción de la dimensionalidad

ya que en general el funcionamiento de un clasificador es pesado computacionalmente en ese sentido para poder alivianar el proceso es que se debe realizar reducción del espacio de características el es realizados con el *Canonical discriminant analysis (CDA) + Support vector machine*.

4.5.1 *Canonical discriminant analysis (CDA)*

El CDA es una técnica, que busca maximizar el espacio de separación entre las clases en ese sentido similar que el análisis de componentes principales y otros métodos como el análisis de discriminate multiple, etc. Estos métodos buscan el espacio de combinación lineales de las características originales en el espacio llamado de variables canónicas. para poder realizar este proceso es necesario tener una idea del espacio entre clases diferentes así como la distan dentro de una misma clase. Sea U la matriz de dispersion de un vector de características el es definido de la siguiente manera:

$$U = \sum_{i=1}^N (\mathbf{x}_i - \mu)(\mathbf{x}_i - \mu)^t \quad (11)$$

donde μ es el grado promedio de todo el conjunto de muestras. Esta ecuación representa la dispersion del conjunto total de los distintos vectores de características pertenecientes a diferentes clases. Entonces sea U_i la matriz que indique la dispersion de los vectores pertenecientes a una misma clase.

$$U_i = \sum_{i \in C_i}^N (\mathbf{x}_i - \mu_i)(\mathbf{x}_i - \mu_i)^t \quad (12)$$

donde C_i es el conjunto de muestras de la clase i y μ_i es el valor promedio de la clase i . Entonces el valor de variabilidad entre elementos de una misma clases puede ser definida por U_{intra_clase} y para el caso de la variabilidad entre clases distintas sera U_{inter_clase} las cuales pueden calcularse como:

$$U_{intra_clase} = \sum_{i=1}^K U_i \quad (13)$$

$$U_{inter_clase} = \sum_{i=1}^K N_i (\mu_i - \mu)(\mu_i - \mu)^t \quad (14)$$

siendo que el valor de K es el numero de clases y N_i el numero de muestras en la clase i . Para esas medidas de dispersion de los datos serán combinados en una nueva matriz U la cual sera

la combinación lineal como se puede ver en la siguiente ecuación 15:

$$U = U_{intra_clase} + U_{inter_clase} \quad (15)$$

Para poder separar estos conjuntos existe una función que podría discriminar las diferentes clases con la siguiente ecuación 16 la cual esta formada por las variables canónicas:

$$Y_i = a_{i1}X_1 + a_{i2}X_2 + \dots + a_{ip}X_p \quad (16)$$

donde p es el numero de características y a_{ij} son los elementos de los autovectores $a_i = (a_{i1} + a_{i2}) + \dots + a_{ip}$ de la matriz C la cual esta dada por:

$$C = S_{inter} \times S_{intra}^{-1} \quad (17)$$

Esta matriz C sera la encargada de reducir la dimensionalidad de los vectores de entrada y de esa manera hacer que el proceso siguiente sea menos pesado, en el caso de la propuesta se uso las maquinas de vectores soporte que es una técnica de clasificación supervisada.

4.5.2 Maquinas de vectores soporte (MVS)

Las maquinas vectores soporte son clasificadores capaces de encontrar una funciones de discriminación que pueden ser lineales o n lineales que se usan para separar el espacio de representación en regiones correspondientes a cada una de las clases consideradas (Vapnik, 2000).

MVS mapea los puntos de entrada a un espacio de características de una dimensión y encuentra un hiperplano que los separe y maximice el margen m entre las clases en este espacio como se aprecia en la 4.9. Maximizar el margen de separación m implica un problema de optimización de programación cuadrática que puede ser resuelto usando los multiplicadores de Lagrange. De tal manera que se encuentra el hiperplano óptimo de separación utilizando el producto punto con funciones en el espacio de características que son llamadas kernels. Este hiperplano es la combinación de unos pocos puntos correspondiente a los patrones de entrada que son llamados vectores de soporte. Existen dos casos que esta técnica puede resolver: problemas linealmente separables y no linealmente separables.

4.5.2.1 Caso linealmente separable

Supongamos que nos han dado un conjunto S de puntos etiquetados para entrenamiento como se aprecia en al Figura 4.9




Figura 4.9: Caso linealmente separable

Cada punto de entrenamiento $x_i \in \mathfrak{R}^n$ pertenece a alguna de dos clases y se le ha dado una etiqueta $y_i \in \{1, -1\}$ para $i = 1, \dots, l$. En la mayoría de los casos, la búsqueda de un hiperplano adecuado en un espacio de entrada es demasiado restrictivo para ser de uso práctico. Una solución a esta situación es mapear el espacio de entrada en un espacio de características de una dimensión mayor y buscar el hiperplano óptimo. Deseamos encontrar el hiperplano

$$W \cdot z + b = 0 \quad (18)$$

definido por el par (w, b) , tal que podamos separar el punto x_i , de acuerdo a la función

$$f(x_i) = \text{signo}(W \cdot z_i + b) = \begin{cases} 1 & \text{si } y_i = 1 \\ -1 & \text{si } y_i = -1 \end{cases} \quad (19)$$

donde $w \in Z$ y $b \in \mathfrak{R}$, el conjunto S se dice que es linealmente separable si existe (w, b) tal que las siguientes inecuaciones:

$$\begin{cases} W \cdot z_i + b \geq 1 \\ W \cdot z_u + b \leq -1 \end{cases} \quad i = 1, \dots, l \quad (20)$$

Sean válidas para todos los elementos del conjunto S . Para el caso linealmente separable de S , podemos encontrar un único hiperplano óptimo, para el cual, el margen entre las proyecciones de los puntos de entrenamiento de dos diferentes clases es maximizado.

4.5.2.2 Caso no linealmente separable

Si el conjunto S no es linealmente separable entonces ocurrirán errores en la clasificación de la SVM, como puede ser visto en la siguiente figura 4.10 no se puede establecer una linea de separación para resolver el problema dado que los datos tienen una distribución circular estando una clases dentro de otra clase. Para tratar con datos que no son linealmente separables,




Figura 4.10: Caso no linealmente separable

el análisis previo puede ser generalizado introduciendo algunas variables no-negativas $\xi_i \geq 0$ de tal modo que la ecuación 20 es modificado a

$$y_i(w \cdot z_i + b) \geq 1 - \xi_i, \quad i = 1, \dots, l \quad (21)$$

Los $\xi_i \neq 0$ en (3) son aquellos para los cuales el punto x_i no satisface la ecuación 19. Entonces el término $\sum_{i=1}^l \xi_i$ puede ser tomado como algún tipo de medida del error en la clasificación.

El problema del hyperplano óptimo es entonces redefinido como la solución al problema

$$\begin{aligned} \min \{ & \frac{1}{2} w \cdot w + C \sum \xi_i \} \\ y_i(w \cdot z_i + b) & \geq 1 - \xi_i, \quad i = 1, \dots, l \\ \xi_i & \geq 0, \quad i = 1, \dots, l \end{aligned} \quad (22)$$

donde C es una constante. El parámetro C puede ser definido como un parámetro de regularización. Este es el único parámetro libre de ser ajustado en la formulación de la SVM. El ajuste de éste parámetro puede hacer un balance entre la maximización del margen de separación entre clases lo cual afecta a la clasificación.

Encontrar el hiperplano óptimo en la ecuación 22 es un problema de programación cuadrática, que puede ser resuelto construyendo un Lagrangiano y transformándolo en el dual:

$$\begin{aligned} \max W(\alpha) &= \sum \alpha_i - \frac{1}{2} \sum \sum \alpha_i \alpha_j y_i y_j z_i z_j \\ \text{donde } \sum y_i \alpha_i &= 0, \quad 0 \leq \alpha_i \leq C, i = 1, \dots, l \end{aligned} \quad (23)$$

donde, $w \in Z$ y $b \in R$, $\alpha = (\alpha_1, \dots, \alpha_l)$ es un vector de multiplicadores de Lagrange positivos asociados con las constantes en la ecuación 21.

Finalmente la idea es encontrar los valores de los pesos w de tal manera que sea el hiperplano óptimo de separación según la siguiente fórmula

$$W = \sum \alpha_i y_i z_i \quad (24)$$

Utilizando la función $\text{signo}(w \cdot z + b)$ se podrá determinar la respuesta correcta a nuestro problema

El uso de MVS puede usar varios kernels para poder clasificar los datos, la forma genérica es $K(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j)$, es necesario probar con diferentes kernels:

- Linear: $K(x_i, x_j) = x_i^T x_j$
- Polynomial: $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
- Radial basis function(RBF):
 $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$
- Sigmoid: $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$

4.6 Validación cruzada

Para poder validar los modelos de reconocimiento se planteó realizar la validación cruzada esta es una técnica que se aplica al conjunto de datos inicial y se usa para evaluar de forma más o menos exacta la calidad de un modelo de clasificación. La mayor ventaja de este diseño experimental es que las estimaciones del error sobre los conjuntos de test son independientes (los conjuntos de test no se solapan). Sin embargo, sí existe un cierto solapamiento en lo que se refiere al conjunto de entrenamiento, ya que cada pareja de conjuntos de entrenamiento comparte una alta fracción de los ejemplos pero a pesar de esto es una de las técnicas más usadas para validar un modelo.

En este método, los datos disponibles que tienen dimension n se dividen aleatoriamente en k conjuntos de ejemplos disjuntos de igual tamaño, $T_1, \dots, T_k$. Se realizan k experimentos, usando como conjunto de entrenamiento en la iteración i -ésima $\bigcup_{j \neq i} T_j$ y como conjunto de test T_i .

En esta tesis se uso un tipo particular de validación que es *leave-one-out*. Este tipo de validación es un caso particular de la validación cruzada en el que k coincide con el número total de patrones de aprendizaje n del conjunto de total de patrones. Estaríamos ante el caso más extremo, ya que cada modelo estaría entrenado con $n - 1$ casos y probado con el caso restante no usado. Este es el método de validación que devuelve resultados más exactos, pero su gran inconveniente es la necesidad de entrenar tantos modelos como casos tuviera el conjunto de datos inicial y el coste computacional necesario para llevar a cabo el proceso puede llegar a ser muy elevado. Pero el nivel de confianza en este tipo de pruebas es mayor que otros métodos.

4.7 Consideraciones finales


Los modelos propuestos intentan mantener las características propias de cada tipo de señal eso es importante para las operaciones de reconocimiento. En el caso de la serie temporal la secuencia de estados según la temporalidad se mantiene y su análisis es realizado a nivel de estructura topológica lo que es importante ya que la dinámica de un sistema es analizado desde otro enfoque. En el caso de las imágenes las características de contornos, texturas e intensidades de gris se mantienen en la representación mediante red compleja lo que también es deseado en cualquier técnica de reconocimiento de patrones.

Resultados experimentales


El modelo propuesto fue probado en dos aplicaciones distintas, una para el caso de series temporales donde el modelo fue usado para el reconocimiento de palabras habladas. En este caso se demostró como el modelo puede servir para extraer características de una señal de voz, las palabras habladas corresponden a la grabación de los numeros del cero al nueve. Por otro lado el modelo también fue probado para el reconocimiento de imágenes, en un proyecto que se desarrolla en el marco de la cátedra Concytec, el proyecto consiste en el reconocimiento de parásitos helmintos, en esta aplicación se demostró la aplicabilidad del modelo propuesto los resultados serán presentados en las siguientes secciones.

5.1 Resultados de la aplicación para el reconocimiento de palabras

Para el reconocimiento de palabras el modelo es usado para demostrar la aplicabilidad en el reconocimiento de señales de voz. El modelo propuesto usa el criterio del par ordenado (A, t) donde A es el valor de amplitud de la señal y t es el tiempo de duración de la grabación.



(a) Señales de las palabras grabadas de los dígitos del 1 al 9



(b) Tres muestras de una misma palabra grabada

Figura 5.1: Gráfica de las amplitudes de las palabras grabadas: En la figura(a) son nueve palabras diferentes; el numero Uno, Dos, Tres, Cuatro, Cinco, Seis, Siete, Ocho y Nueve; En la figura (b) Muestras de una misma palabra pueden ser vistas

5.1.1 Adquisición, Cuantificación y Muestreo

El primer paso a desarrollar es la adquisición, cuantificación y muestreo de la señal. Para dicho propósito se elaboro una base de datos de palabras habladas de los dígitos del uno al nueve de los cuales se tuvo veinte ejemplares de cada palabra obteniéndose un total de 180 palabras, para la grabación se utilizó un micrófono multimedia y la tarjeta de sonido de un computador personal, la frecuencia de muestreo de la grabación fue de 44100 hz y la cuantificación fue realizada a 16 bits.

En la siguiente figura 5.1 se puede apreciar algunas de las palabras grabadas, como se puede apreciar la forma de las amplitudes de la señal son diferentes para palabras diferentes, esa motivación ayuda a que la representación mediante redes complejas ayudara a acentuar esas diferencias cuando sean representadas como redes complejas.




Figura 5.2: Determinación de ventanas solapadas para la detección del inicio y fin de palabra

5.1.2 Detección de inicio y fin

Una vez realizada la adquisición, es necesario implementar un algoritmo detector de inicio y fin de la señal con el objetivo de eliminar información redundante de la señal (eliminar el fondo, segmentando el inicio y el final de la señal de voz propiamente dicho).




Figura 5.3: Determinación de ventanas solapadas para la detección del inicio y fin de palabra

Este proceso de segmentación se realiza a través del cálculo de energía y detección de umbrales de actividad de señal, el algoritmo basa sus cálculos en promedios temporales (mediante el análisis una ventana de tiempo rectangular) del valor absoluto de la señal, el valor calculado de la energía de la señal en esa ventana esta dado por la siguiente ecuación:

$$E = \frac{1}{N} \sum_{i=1}^N |x(i)|^2 \quad (1)$$

donde el valor de E (energía) es comparado con un umbral T , si el valor es mayor que ese umbral se dice que corresponde a la señal de voz y si es menor entonces se dice que es ruido

(fondo de la señal), la venta es solapada como se puede ver en la figura 5.3. Para determinar el valor de umbral se calculo la energía de un segmento de ruido en ese sentido es necesario grabar una porción de ruidos para una ventana dada, en este caso el tamaño de la venta es de 400 y el valor del umbral en promedio es $T = 0.8$ el cual garantiza diferencia la señal de voz y el ruido de la misma. Una vez determinado el inicio y fin de una palabra el siguiente paso es extraer las características mediante redes complejas y finalmente se realiza la clasificación usando un clasificador.

5.1.3 Extracción de características

Para poder extraer las características se uso el modelo propuesto para reconocimiento de series temporales, el cual fue explicado en la sección 4.3, en el cual se construyeron varias redes en función a la distancia entre cada par ordenado (A, t) que compone la serie temporal, en la detección del inicio y fin de una palabra el tamaño de las palabras tiene dimensiones distintas pero todas ellas son normalizadas a un intervalo entre $[0 : 1]$ eso ayuda a la extracción de características independientemente de la cantidad de elementos que tenga el vector de la señal. El efecto de crear la red para diferentes distancias se puede ver en la figura 5.4 en el cual se puede ver un segmento de la serie temporal, el cual corresponde 300 muestras de la serie temporal y se varia el umbral de conectividad, el que indica la distancia maxima entre cada par de nodos de la red. Como se puede ver a medida que el valor del umbral aumenta el número de conexiones también se incrementa.

El vector de características es obtenido mediante la creación de diferentes redes, donde el parámetro de umbral U varia desde $U_1 = 0.01$ hasta el valor de $U_{386} = 0.9$ con incrementos de $\delta T < 0.0025$ dando un total de 356 características, según las pruebas realizadas este parámetro presente los mejores resultados.

5.1.4 Clasificación de las palabras habladas

Para la clasificación de las palabras habladas, el modelo debe ser capaz de discriminar entre los diferentes sonidos de entrada realizando el reconocimiento de cada una de éstas con respecto a un conjunto de datos previamente aprendido. Primero los datos obtenidos en la extracción de características fueron reducidos de su dimensionalidad usando *Canonical discriminant analysis* donde la dimension de 356 es reducida a 9 variables canónicas dado que existen 9 clases de palabras en la siguiente figura 5.5 se puede apreciar gráficamente la relación entre algunas de estas variables canonicas, donde se puede se puede ver que en algunos sub espacios pertenecientes




Figura 5.4: Redes construidas para diferentes distancias

a una misma palabra las cuales son de un mismo color, los elementos están separados casi totalmente de otro sub conjunto, eso hace notar que habrá una clasificación adecuada.

Para las pruebas del modelo propuesto fue realizado la validación cruzada del tipo *leave-one-out* usando como método de clasificación la maquina de soporte vectorial. Para poder probar la maquina de soporte vectorial es necesario probar con diferentes parámetros siendo uno de los principales el kernel que se debe usar, según el tipo de kernel se deben definir ciertos parámetros como por ejemplo en el caso de un polinomial se debe ingresar como parámetro el grado del mismo que podría ser cuadrático, cubico, etc. Otro parámetro usado también es el de regularización el cual define si existe o no vectores dentro del margen de separación. En ese sentido el modelo final de clasificación es robusto porque fue probado con diferentes variaciones de kernel en la clasificación, kernels como el de base radial entre otros a pesar de obtener resultados no adecuados, cometiendo mucho error por eso no fueron considerados en las estadísticas, eso hace notar que los grupos formados no tienen distribución de datos de funciones de base radial.

Por otro lado en lo correspondiente a la creación de la red se probó con la variación del parámetro de conectividad delta δT al momento de extraer características, hay tomar en cuenta que a menor valor de δT mayor cantidad de características. Como podemos ver en la siguiente




Figura 5.5: Relación entre las diferentes variables canónicas

tabla 5.6 donde el parámetro de conectividad fue incrementandose gradualmente, de tal manera de poder encontrar los parámetros correctos para la clasificación de nuestro problema.

Finalmente podemos ver los resultados en la tabla 5.6, como se pudo ver cuando el valor de $\Delta T = 0.006$ el porcentaje de acierto es el 99.99% tanto para el kernel polinomial como para el lineal, pero si observamos la matriz de confusión el error se da en palabras diferentes, por eso a continuación mostraremos las 2 matrices de confusion para los dos casos:

El caso del kernel lienal lo podemos ver en la tabla 5.2 donde el error de clasificación se da en la palabra cuatro, el cual es confundido con la palabra ocho eso significa que de los veinte ejemplares correspondientes a la palabra cuatro uno de ellos fue clasificado incorrectamente como clase 8, por otro lado los del tipo ocho si fueron correctamente clasificados pero en la

Clasificador	Nro. de características	Nro. de imágenes correctas	Porcentaje % Acierto	ΔT
SVM - Lineal	890	166	92.22	0.001
SVM - Polinomial	890	163	90.55	0.001
SVM - Lineal	445	161	89.00	0.002
SVM - Polinomial	445	163	90.55	0.002
SVM - Lineal	222	171	95.00	0.004
SVM - Polinomial	222	171	95.00	0.004
SVM - Lineal	148	179	99.44	0.006
SVM - Polinomial	148	179	99.44	0.006
SVM - Lineal	110	164	91.11	0.008
SVM - Polinomial	110	166	92.22	0.008
SVM - Lineal	89	159	83.33	0.01
SVM - Polinomial	89	149	82.77	0.01

Tabla 5.1: Comparación de los resultados para diferentes parámetros del modelo propuesto.

recuperación de sus valores uno a mas fue realizado. Sin embargo en el caso del kernel polinomial los resultados de error son diferentes al caso anterior, en este caso el error se da en la recuperación de la palabra ocho, como se puede ver en la tabla 5.3, donde hay una palabra ocho que no fue recuperada correctamente y podemos ver que el caso de la palabra cuatro uno a mas fue reconocido siendo este el contrario del caso anterior, eso quiere decir que la separación entra la palabra ocho y cuatro tienen una dificultad al momento de separar dichas clases.

5.2 Reconocimiento de parásitos helmintos

Para poder demostrar la aplicabilidad del modelo propuesto en la clasificación de imágenes se utilizó los datos del proyecto PIBAP titulado Sistema automático de diagnóstico de parásitos intestinales a través de imágenes digitales (Contrato 028-2009-FINCYT-UNSA) en ese sentido algunos de los resultados de esta investigación son usados para poder compararlos con los resultados obtenidos con el modelo propuesto. Dado que esta tesis formaba parte del proyecto anteriormente mencionado es que parte de la información de este capítulo fue resultado de informes técnicos, así como artículos publicados en el marco del proyecto del cual se participó como tesista.

Es importante tener en cuenta que un Helminto es un parásito que produce enfermedades infecciosas. Las infecciones parasitarias provocadas por Helmintos están vinculadas a condiciones socio ambientales que aquejan a Peruanos de bajos recursos económicos que viven en condiciones favorables para el desarrollo de estos parásitos: cambios climáticos, alimentación insuficiente, vivienda precaria, tierra contaminada, ausencia de agua potable, etc (Flint et al., 2005).

	1	2	3	4	5	6	7	8	9	Co(%)
1	100.0									0
2		100.0								0
3			100.0							0
4				95.0				5.0		5.0
5					100.0					0
6						100.0				0
7							100.0			0
8								100.0		0
9									100.0	0
Om(%)	0	0	0	0	0	0	0	5.0		99.44

Tabla 5.2: Matriz de confusion, cons sus respectivos error por cada clase, usando SVM con kernel lineal.

	1	2	3	4	5	6	7	8	9	Co(%)
1	100.0									0
2		100.0								0
3			100.0							0
4				100.0						0
5					100.0					0
6						100.0				0
7							100.0			0
8				5.0				95.0		5.0
9									100.0	0
Om(%)	0	0	0	5.0	0	0	0	0		99.44

Tabla 5.3: Matriz de confusion, cons sus respectivos error por cada clase, usando SVM con kernel polinomial.

Usualmente en puestos de salud publica de comunidades de bajos recursos del Perú no se dispone de personal capacitado para diagnosticar enfermedades provocadas por estos parásitos. Habitualmente para realizar el diagnóstico en este caso se recurre a recolectar muestras de heces de los pacientes y enviarlas a la ciudad más cercana para que realicen el diagnóstico. La propuesta de realizar un sistema automático de diagnóstico tiene por objetivo principal realizar un diagnóstico en tiempo real tomando las muestras de las imágenes de las micrografías desde un microscopio y reducir el tiempo de espera para poder realizar un diagnóstico rápido. Automatizar este proceso que normalmente es realizado por personal altamente capacitado como Biólogos expertos en parasitología, se dificulta al depender de procesos variables no automatizables como el procedimiento sedimentación y centrifugación de la muestra, incluso posterior a este procedimiento es necesario aplicar una solución química sobre la micrografía para resaltar los parásitos ante el ojo humano.

Actualmente los biólogos para distinguir a un parásito de un artefacto no deseado se basan en la morfología de los Helmintos que normalmente son circulares y ovoides, el siguiente paso para realizar el descarte es distinguir si la textura es rugosa o lisa; no consideran al color como una característica relevante por ser directamente dependiente de las soluciones químicas que aplican a la micrografía para que los candidatos puedan ser resaltados de mejor manera para el ojo humano. Cabe resaltar que los biólogos caracterizan a estos parásitos para poder identificarlos correctamente. Por eso con el modelo propuesto que integra la característica de la forma de los objetos así como la textura de la misma, es algo que podría beneficiar a la automatización del diagnostico de los parásitos por considerar aspectos que los biólogos resaltan en su diagnostico.

5.2.1 Conjunto de datos

Los experimentos fueron realizados sobre la base de datos SADPI8 v2.0 proporcionada por el grupo PibapUnsa¹ que contiene imágenes microscópicas extraídas de dos laboratorios de diferentes ciudades del Perú, algunas imágenes de dicha base son mostrados en la figura 5.6. Las imágenes fueron obtenidas con un microscopio óptico (MOTIBAC) el cual esta acoplado a un ordenador por el cual se capturan imágenes con una magnificación objetiva $40\times$ en formato JPG. Los nombres de los parásitos que fueron usados para probar el modelo están listados en el cuadro 5.4 y pueden ser vistos en la figura 5.7. El conjunto de imágenes de micrografías por especie así como imágenes segmentadas de entrenamiento están puestos en el siguiente cuadro 5.4. Como se puede apreciar hay un total de 1036 imágenes como se puede apreciar no existe la misma cantidad de imágenes por cada tipo de parásito, eso debido a que la incidencia de un tipo de parásito es mayor que los otros.

¹The website of this project is www.pibapunsa.org




Figura 5.6: Imágenes de la base de datos SADPI8 v2.0

Es importante notar que las imágenes originales capturadas desde el microscopio son como las mostradas en la figura 5.6 donde podemos ver que existe la presencia de parásitos y además de otros objetos a los cuales se llamaran artefactos por eso es necesario realizar la segmentación de los objetos de interés (parásito), pero ese proceso no fue implementado en esta tesis ya que el trabajo fue realizado por (Chuctaya et al., 2010) proporcionando los parásitos ya segmentados estas imágenes fueron las que se usaron para probar el modelo.

Es importante notar que cada tipo de parásito es diferente y tienen características propias, en la siguiente figura 5.7 se pueden apreciar las imágenes de cada uno de los helmintos a reconocer como se puede ver tienen diferentes características que fueron formalizadas por descripciones de los especialistas de la facultad de medicina de la Universidad Nacional de San Agustín.

Dicha formalización realizada por los expertos serán comentadas a continuación:

1. **Trichiuris trichiura:** Los huevos de esta especie tienen una forma o aspecto de limón, con dos prominencias polares translúcidas, semejantes a tapones. El tamaño varía de 50

Especie	Num de micrografías	Num de muestras segmentadas
<i>Ascaris Lumbroides</i>	100	81
<i>Uncinarias</i>	75	51
<i>Trichuris Trichiura</i>	102	106
<i>Hymenolepis Nana</i>	115	74
<i>Dyphillobothrium</i>	103	164
<i>Taenia Solium</i>	211	231
<i>Fasciola Hepatica</i>	280	259
<i>Enterobius Vermicularis</i>	91	70
Total	866	1036

Tabla 5.4: Cantidad de micrografías por especie y parásitos segmentados encontrados en las micrografías




Figura 5.7: Nombres de parásitos: 1) *Ascaris* 2) *Uncinarias* 3) *Trichuris trichiura* 4) *Hymenolepis nana* 5) *Dyphillobothrium pacificum* 6) *Taenia solium* 7) *Fasciola hepática* 8) *Enterobius vermicularis*

a 54 por 23 micras. Presenta una capa externa de color amarillento y una capa interna transparente. Los huevos fertilizados al momento de la oviposición = al ser expulsados

al exterior no muestran segmentación. El desarrollo embrionario tiene lugar fuera del huésped.

2. **Uncinarias por las especies *Necator americanus* y *Ancylostoma duodenale*:** Los huevos de estas dos especies, son casi indistinguibles, difieren solo ligeramente en el tamaño. *N. americanus* es de 64 a 76 por 36 a 40 micras mientras que los de *A. duodenale* son de 56 a 60 por 36 a 40 micras (hecho que el ojo humano no diferencia de manera rutinaria). Los huevos tienen extremidades romas, redondeadas, y una capa hialina transparente, delgada, no están segmentados en la oviposición. En las heces frescas se les encuentra con dos a ocho etapas celulares de división.
3. ***Ascaris lumbricoides*:** Los huevos miden de 45 a 70 por 35 a 50 micras. Una cubierta externa densamente mamelonada, albuminosa que sirve de barrera auxiliar contra la permeabilidad, a veces puede faltar. El huevo propiamente dicho tiene una capa gruesa, transparente, hialina con cubierta externa relativamente gruesa, que actúa como estructura de sostén y otra interna, vitelina, delicada, lipoidal y muy impermeable. En el momento de la oviposición, la cubierta contiene una masa ovoide de protoplasma no segmentado, densamente impregnada con gránulos de lecitina. Los huevos no fértiles son mas largos y estrechos, miden de 88 a 94 por 39 a 44 micras, tiene una cubierta más delgada y otra irregular albuminosa, estando completamente llenos de una masa amorfa de protoplasma, son gránulos retráctiles. También, hay huevos de aspectos caprichosos, sin cubierta albuminosa, con cubiertas externa anormales irregularmente. Generalmente los huevos no fértiles, son difíciles de identificar y pueden pasar inadvertidos ante los ojos de un observador poco acucioso=poco entrenado.
4. ***Enterobius vermicularis*:** Los huevos de esta especie son difíciles de encontrar en un examen de heces rutinario. Se les puede identificar muy rápidamente por su aspecto asimétrico y por su contenido, un embrión bien desarrollado.
5. ***Diphyllobothrium pacificum*:** Los huevos miden de 55 a 76 por 41 a 56 micras, tiene una capsula simple con un opérculo medio oculto en uno de sus extremos y muestra un pequeño engrosamiento en forma de botón en el otro.
6. ***Hymenolepis nana*:** El huevo es de forma oval o globular, miden de 47 por 37 micras. Presentan dos membranas que encierran un embrión hexacanto. La membrana interna tiene dos engrosamientos polares, de cada uno de ellos nacen de cuatro a ocho filamentos polares muy finos.
7. ***Taenia saginata* / *Taenia solium*:** Los huevos de estas especies no pueden distinguirse con facilidad, son prácticamente iguales. Son de un color amarillo pardusco, con una cubierta

estriada radialmente que encierran un embrióforo. Miden de 30 a 40 por 20 a 30 micras. Algunas veces se pueden observar huevos rodeados por una capa o membrana externa con dos delicados filamentos polares (como se encuentran en el útero del céstodo), pero que se pierden inmediatamente dejan el proglótido del céstode. Alguno autores, señalan que los huevos maduros de *Taenia solium*, son indistinguible de los de *Taenia saginata*, contiene un embrión hexacanto rodeado por una cubierta esférica o semiesférica, estriada, gruesa, de color café claro y con un tamaño de 30 por 40 micras de diámetro.

8. **Fasciola hepática:** Los huevos de esta especie, son grandes y ovales, de color amarillo - pardusco. Son operculados y miden de 130 a 150 por 65 a 90 micras; no presentan segmentación al momento de la oviposición (cuando son expulsados al exterior).

Una muestra de la base de datos de imágenes usada se puede ver en la siguiente imagen 5.8:

Estas características formalizadas ayudaron a determinar las técnicas de procesamiento de imágenes necesarias para que estas pueden ser cuantificadas en un vector de características, por eso es necesario dar conceptos teóricos de dichas técnicas ya que estas fueron implementadas y probadas para poder comparar el modelo propuesto frente a técnicas ampliamente usadas en el reconocimiento automático de imágenes.

5.2.2 Técnicas de extracción de características

La propuesta esta fundamentada en la simulación de los criterios de los biólogos donde la morfología de los parásitos fue uno de los criterios tomados en consideración, otro aspecto importante es la textura. En el artículo (Humpire et al., 2011), mostraron resultados de clasificación en los cuales el vector de características es de tamaño 8 y esta compuesto por dos descriptores: 4 geométricas y 4 de textura *Gray Level Co-Occurrence Matrix* (GLCM) que usan el contorno y la imagen en escala de grises del candidato. A continuación describiremos la técnica usada en el artículo para poder comparar los resultados con los obtenidos por esta propuesta.

5.2.2.1 Características geométricas

Para poder definir la morfología del candidato es importante detectar el contorno exterior del parásito para poder detectar el contorno se uso el filtro de Canny (Canny, 1986). La detección del borde es un enfoque común para detectar discontinuidades diferenciales en imágenes en niveles de gris. Para lograr dicho objetivo se usa la primera y segunda derivada como gradientes y el laplaciano para detectar bordes en una imagen.



Figura 5.8: Muestra de imágenes de diferentes parásitos de la base de datos usada para la clasificación de parásitos

Un borde es un conjunto de puntos con el mismo nivel de intensidad entre los píxeles de la imagen. Los bordes en una imagen pueden generalmente ser divididos en dos categorías de bordes de intensidad (abruptos cambios) y borde de textura (regiones invariantes a condiciones de luminosidad) (Tan et al., 1989). Este método es ideal para especies que tienen una cubierta semitransparente en vista que la binarización puede obviar varias partes que imposibiliten su proceso normal.

Para poder realizar la detección de contornos mediante el algoritmo de Canny los siguientes pasos tienen que ser realizados:

5.2.2.2 Obtención del gradiente

Para la obtención del gradiente el método utiliza el filtro gaussiano aplicado a la imagen original, con el propósito de suavizar la imagen y trata de eliminar posible ruido existente, pero hay que tener en cuenta que no se debe realizar un suavizado excesivo ya que implicaría pérdida de características de la imagen, y generaría resultados no óptimos. Una vez que se suaviza la imagen, para cada píxel se obtiene la magnitud y módulo (orientación) del gradiente, obteniendo así dos imágenes. El suavizado del filtro gaussiano se obtiene promediando los valores de intensidad de los píxeles en el entorno de vecindad con una mascara de convolución de media cero y desviación estándar σ , la mascara gaussiana esta definida por la siguiente ecuación:

$$G(x, y) = ke^{(x^2+y^2)/2\sigma^2} \quad (2)$$

El gradiente de una imagen $f(x, y)$ en un punto (x, y) se define como un vector bidimensional dado por la ecuación:

$$G[f(x, y)] = \begin{bmatrix} G_x \\ G_y \end{bmatrix} \quad (3)$$

siendo el gradiente un vector perpendicular al borde, donde el vector G apunta en la dirección de variación máxima de la función F en el punto (x, y) , la magnitud y dirección están dadas por:

$$|G| = \sqrt{G_x^2 + G_y^2} = |G_x| + |G_y| \quad (4)$$

$$\Theta(x, y) = \arctan \frac{G_y}{G_x} \quad (5)$$

siendo $|G|$ la magnitud del gradiente y $\Theta(x, y)$ la dirección del gradiente.

5.2.2.3 Supresión de no-máximos al resultado del gradiente

Las imágenes generadas en el paso anterior sirven de entrada para generar una imagen con los bordes adelgazados. El procedimiento es el siguiente, se consideran cuatro direcciones identificadas por las orientaciones de 0° , 45° , 90° y 135° con respecto al eje horizontal. Para cada píxel se encuentra la dirección que mejor se aproxime a la dirección del ángulo de gradiente.

5.2.2.4 Histéresis de umbral

Del resultado del proceso anterior se obtiene una imagen que suele contener máximos locales creados por el ruido. Una solución para eliminar dicho ruido es la histéresis basada en umbral.

El proceso consiste en tomar la imagen obtenida del paso anterior, tomar la orientación de los puntos de borde de la imagen y tomar dos umbrales, el primero más pequeño que el segundo. Para cada punto de la imagen se debe localizar el siguiente punto de borde no explorado que sea mayor al segundo umbral. A partir de dicho punto seguir las cadenas de máximos locales conectados en ambas direcciones perpendiculares a la normal del borde siempre que sean mayores al primer umbral. Así se marcan todos los puntos explorados y se almacena la lista de todos los puntos en el contorno conectado. Es así como en este paso se logra eliminar las uniones en forma de Y de los segmentos que se unan en un punto.

5.2.2.5 Cierre de contornos abiertos

Como resultado del proceso anterior es posible hayan contornos abiertos, para poder cerrar estos contornos se busca cada píxel uno de los ocho patrones posibles que delimitan la continuación del contorno en tres direcciones posibles. Esto se logra con la convolución de cada píxel con una máscara específica. Cuando alguno de los tres puntos es ya un píxel de borde se entiende que el borde se ha cerrado, de lo contrario se elige el píxel con el valor máximo de gradiente y se marca como nuevo píxel de borde y se aplica nuevamente la convolución. Estos pasos se repiten para todo extremo abierto hasta encontrar su cierre o hasta llegar a cierto número de iteraciones determinado.

Una vez detectado el contorno se procede a obtener algunas características que son:

- Diámetro máximo, es la mayor distancia existente entre dos puntos del contorno.
- Diámetro mínimo, es la distancia ortogonal desde el punto medio de la línea generada por el diámetro máximo hacia el contorno.
- Área, píxeles contenidos en el contorno del parásito. Logra distinguir los parásitos grandes de los pequeños
- Excentricidad, es la proporción existente entre el diámetro máximo y diámetro mínimo, esta característica ayuda a diferenciar a los huevos de parásitos que son ovóides de los circulares.

5.2.2.6 Características de textura interna *Gray Level Occurrence Matrix*

Esta técnica fue propuesta por (Lam, 1996) La matriz de co-ocurrencia describe la frecuencia de un nivel de gris que aparece en una relación espacial específica con otro valor de gris, dentro del área de una ventana determinada. La matriz de co-ocurrencia es un resumen de la forma en que

los valores de los píxeles ocurren al lado de otro valor en una pequeña ventana. Normalmente el procedimiento de generación de imágenes de textura requiere que el analista defina cinco variables:

- Tamaño de la ventana
- Banda espectral de entrada
- Las texturas derivadas
- Cuantización (numero de bits) del canal de salida
- La componente espacial (la distancia interpixel y el ángulo para el computo de la co-ocurrencia).

Respecto del tamaño de la ventana, esta debe ser cuadrada y con numero impar de píxeles. El resultado del calculo de la textura es un único numero que representa la ventana completa, el cual es colocado en el lugar del pixel central. Luego, la ventana se mueve un pixel y el calculo se repite calculando una nueva matriz de co-ocurrencia para esta nueva ventana y resultando un nuevo valor, para el píxel central de esta nueva posición de la ventana. De este modo se construye toda una nueva imagen con valores de texturas. Cada celda de la ventana debe situarse en una celda que esté ocupada en la imagen original. Esto significa que el pixel central de la ventana no puede ocupar un borde la imagen.

Las características de textura GLCM (Lam, 1996) están basadas en la matriz de co-ocurrencia sobre la imagen segmentada en escala de grises. La matriz de co-ocurrencia es una matriz cuadrada de $N \times N$, donde N es el número de posibles valores en la imagen (niveles de gris). La posición C_{ij} de la matriz representa la cantidad de píxeles de nivel i que están a una distancia y en una dirección de otro pixel de nivel j .

Una vez obtenida la matriz de co-ocurrencia esta debe pasar por una normalización. Después se debe escoger el descriptor apropiado que reducirá la matriz de co-ocurrencia a un solo valor (En este caso un descriptor de contraste). Las pruebas fueron realizadas usando 8 niveles de umbral y desplazamientos $\delta x = 3$, $\delta y = 3$. Las características calculadas son: correlación, energía, contraste y homogeneidad.

La etapa de segmentación retorna imágenes recortadas contenedoras de candidatos con background blanco, esta particularidad es aprovechada para descartar cualquier pixel blanco del conteo para la matriz de co-ocurrencia garantizando así obtener características exclusivamente del candidato en escala de grises.

5.2.2.7 Características de Histograma

Los histogramas (Lin and Lin, 2011) son la representación de la distribución de la intensidad de colores de una imagen, en una imagen en niveles de gris la propuesta tiene valores entre el rango de $[0, 255]$ donde 0 representa el color 0 y el valor de 255 es el blanco. Las características extraídas mediante el histograma se obtiene contando las intensidades de cada pixel de la imagen. Entonces para reducir el numero de características el histograma puede ser representado por cierta cantidad de bins, optimizando la cantidad de atributos de la imagen.

Los valores de los bins son calculados por el promedio de los valores del bucket del histograma original, en ese caso las pruebas fueron realizados con 17 bins, cada bin es resultante del promedio de un bloque de 15 unidades del histograma original.

5.2.2.8 Momentos de HU

En procesamiento de imágenes, los momentos invariantes son usados como un vector de características para su clasificación de imágenes obteniendo atributos de las formas del objeto basadas en su textura. En los años 1960, Hu (Hu, 1962) desarrolló 7 momentos invariantes de escalas, rotación y traslación basados en momentos de teoría algebraica.

En reconocimiento de patrones se ha aplicado una leve modificación de estos momentos invariantes para poder trabajar con imágenes y requiere de ser una matriz cuadrada para poder obtener los 7 momentos de Hu como condición. Los momentos de Hu son 7 y están definidos por las siguientes ecuaciones y son dependientes de sus anteriores ecuaciones:

$$\varphi_1 = \eta_{20} + \eta_{02} \quad (6)$$

$$\varphi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11} \quad (7)$$

$$\varphi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (8)$$

$$\varphi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{03} + \eta_{21})^2 \quad (9)$$

$$\varphi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) \left[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \left[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] \quad (10)$$

$$\varphi_6 = (\eta_{20} - \eta_{02}) \left[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \quad (11)$$

$$\varphi_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12}) \left[(\eta_{30} + \eta_{23})^2 - 3(\eta_{21} + \eta_{03})^2 \right] - (\eta_{30} - 3\eta_{12})(\eta_{03} + \eta_{12}) \left[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 \right] \quad (12)$$

5.2.2.9 Filtros de Gabor

Una filtro de Gabor es un complejo sinusoidal modulado por una envolvente Gaussiana. Para el caso de dos dimensiones es una función compleja, sobre puesta a las dos partes del filtro los cuales solapados son equivalentes a una mascara.

Matemáticamente la función compleja de Gabor queda expresada de la siguiente manera:

$$g(x, y) = K e^{(-\pi(a^2(x-x_0)^2 + b^2(y-y_0)^2))} e^{(j(2\pi(u_0x + v_0y) + P))} \quad (13)$$

Y la parte real queda expresada como:

$$g(x, y) = K e^{(-\pi(a^2(x-x_0)^2 + b^2(y-y_0)^2))} e^{(\cos(2\pi(u_0x + v_0y) + P))} \quad (14)$$

Gabor a su vez otorga independencia de escala, rotación y traslación. La independencia de escala es lograda dependiendo de un limite de escalas asignado al momento de extraer características, la independencia de rotación es lograda por las múltiples rotaciones realizadas de forma automática por Gabor teniendo como limite de rotaciones las asignadas al momento de extraer características.

5.2.2.10 K-Gabor

Este extractor de características otorga una particularidad y ventaja para tipos de imágenes que necesitan resaltar detalles de su morfología interna, tal es el caso en el reconocimiento de parásitos ya que no basta con visualizar las características básicas pre-establecidas como alto, ancho, área sino detalles internos para diferenciar entre especies de parásitos.

Esta técnica se apoya en el uso de la clusterización por intensidad de grises usando *K-means* para obtener diferentes niveles de contenido, para el presente caso de estudio se consideraron 5 clusters de los cuales el primer y ultimo cluster son descartados por contener información global de la imagen, en cambio los clusters intermedios contienen información valiosa.

5.2.3 Redes complejas para la clasificación de parásitos

Para poder comparar el modelo propuesto frente a otros ya propuestos usando redes complejas, se implementaron las otras técnicas en la clasificación de los parásitos, en ese sentido se presentaran tres modelos de redes complejas para extracción del vector característico. Primero explicaremos el modelo basado en los contornos, el modelo es el basado en la textura se implemento según la propuesta de (Wesley, 2010) (Backes, 2010), finalmente el modelo propuesto es descrito en detalle.

5.2.3.1 Red compleja basada en contorno

Este modelo se desarrollo en el marco del proyecto STIC-AMSUD (*11STIC-07 - Webbased - Web-based systems for bio-image analysis and interpretation*) donde el modelo se desarrollo el grupo de investigación del profesor Odermir Bruno de la Universidad de Sao Paulo - Brasil el proceso puede ser visto en la figura 5.9:

Como se puede ver (figura 5.9), el método se basa en la detección del contorno externo y la detección de los contornos de las estructuras internas. Para la detección del contorno externo se realiza una binarización de la imagen usando el método propuesto por Otsu (Kurita et al., 1992) una vez teniendo la imagen binarizada se extrae el contorno del parásito binarizado. Para la detección de las estructuras internas se uso el algoritmo de Canny (Canny, 1986) y como ya fue detectado el contorno externo este es eliminado quedando solo la estructura interna.

Como se puede ver en la siguiente figura 5.10 se muestra la figura de algunos parásitos de de especies distintas donde el resultado de la obtención del borde exterior como de las estructuras internas pueden ser apreciados siendo estas diferentes en su estructura interna eso ayuda a compensar con dichas estructuras las texturas que ellos tienen.

Una vez teniendo el contorno se sigue la idea de construir la red según la distancia entre los puntos del contorno donde los valores del umbral varia entre 0.05 a 0.95 con una variación de umbral $\Delta T = 0.005$ siendo un total de 190 intervalos de variación siendo dos vectores el número total seria de 380 características, la propuesta obtiene dos vectores de características, los valores del vector de características son el grado promedio de los nodos de la red.

5.2.3.2 Red compleja basada en textura

Para poder construir la red primero se define una vecindad entre los pixels de la imagen formando una red regular ya que todos los nodos de la red tienen el mismo grado, en ese sentido se debe variar el parámetro de conectividad entre los pixeles, inicialmente el valor es de $\sqrt{2}$ una vez creada la red inicial para poder crear la red se considerara los niveles de intensidad que tienen los pixeles calculando la diferencia de intensidades de tal manera que esta red tendrá pesos $w = |I_i - I_j|$ siempre y cuando los pixeles están conectados es decir que la distancia entre los pixeles es menor que el radio definido inicialmente. Para convertir esta red regular con pesos a una red compleja se usa valores umbrales T para conservar aristas con pesos menores a dicho valor y eliminar aristas con valores mayores, en ese sentido varios umbrales son aplicados.

Una vez creada la red compleja se aplica las caminadas del turista obteniendo diferentes memorias $(\mu_1, \dots, \mu_M)$ y dinámicas mínimo y máximo son aplicadas en cada red compleja. el vector de características es obtenida de la concatenación de los valores anteriores para diferentes umbrales y distintos radios de conectividad.

5.2.4 Red compleja del modelo propuesto

Como se presento en capítulo 4 la red compleja del modelo propuesto es creada en función de la distancia entre los valores de las posiciones de los pixeles y su valor de intensidad, una imagen puede ser analizada de forma tridimensional, es decir que el punto 3D es la combinación de la posición x, y y los niveles de intensidad I siendo estas posiciones los vertices en 3 dimensiones (x, y, I) y en función a la distancia se establecerán las conexiones en la figura 5.11 se puede apreciar la imagen correspondiente al parásito, además se puede ver su visualización en 3D, también podemos ver dos redes construidas en función a dos distancias entre pixeles una es $d = 4$. y el otro es $d = 6$ se puede ver claramente que a menor valor del umbral menor conectividad existen entre vertices de la red, eso dice mucho del efecto que tiene el modelo propuesto ante el cambio de umbral.

Por otro lado se puede ver también que las redes son diferentes eso indica que se pueden diferenciar un tipo de otro eso es importante para las etapas siguientes de tal manera que garantice la efectividad del método al momento de clasificar los parásitos.

Es importante considerar es que el modelo propuesto es invariante a las transformaciones geométricas eso garantiza la robustez de la propuesta, ya que ante el cambio en traslación rotación o escala el valor del vector de características no se ve afectado, las transformaciones geométricas mas comunes son la rotación, traslación y la escala en la figura 5.12 se puede ver el efecto de rotar y escalar la imagen de una *Enterobius Vermicularis*, muy a pesar de las diferentes trans-

formaciones que sufrió la imagen, los vectores de características muestran valores semejantes eso indica que el modelo es invariante a dichas transformaciones, eso hace robusto al modelo ante este tipo de problemas.

Es importante tener en cuenta que el para poder construir la red compleja el fondo de la imagen no es usada, para poder lograr dicho propósito la segmentación del parásito debe ser realizada.

5.2.5 Clasificación de parásitos

Para poder clasificar los parásitos se tiene hacer una reducción de la dimensionalidad, usando el CDA, una vez realizado el proceso de reducción podemos obtener las variables canónicas el cual podemos apreciar en las siguientes figuras 5.13, 5.14.

Como se puede ver en la figura 5.13 al combinar la 8va y la 7ma variable se consigue una separación aceptable entre las variables, pero el parásito *Dyphillobothrium* se sobrepone con otros parásitos eso también sucede con la combinación de otras variables excepto en la combinación de la 5ta variable con la 8va, es importante notar que en ese caso ese conjunto de datos es fácilmente separable, se puede ver también que en varios casos los ascaris, *Ucinarias*, *Faciola hepatica* y *Enterobius vermicularis* en varios casos es separable fácilmente eso indica que dichos parásitos son diferentes entre si. Se puede ver en general que las variables canónicas 1ra y 2da siempre presentan combinación de algunos parásitos lo que dificulta la clasificación. Pero analizando las diferentes combinaciones también se puede ver que en algunos casos siempre existe una separación de cada tipo de parásito.

5.2.5.1 Resultados Estadísticos

Para validar el modelo propuesto se tuvo que realizar varias pruebas modificando el parámetro principal que es la variación del delta δT ya que eso determina el nivel de conectividad de los nodos de la red, donde hay que tomar en cuenta que a menor valor de δT mayor cantidad de características. En la tabla 5.6 se puede ver la modificación del parámetro, de tal manera de poder calibrar el modelo, también fueron probados diferentes kernels pero en los diferentes experimento el polinomial fue el que presento mejores resultados. El parámetro fue variado desde $T = 0.01$ hasta valores menores que $T = 0.9$ para diferentes δT .

ΔT	Nro. de características	Nro. de imágenes correctas	Porcentaje % Acierto
0.001	890	1023	98.74
0.002	445	1008	97.29
0.003	296	957	92.37
0.004	222	738	71.23
0.005	178	745	71.91
0.006	148	688	66.40

Tabla 5.5: Comparación de los resultados para diferentes parámetros del modelo propuesto.

Varios extractores de características han sido probados en el desarrollo de este proyecto, los resultados obtenidos pueden ser resumidos en la siguiente tabla 5.6, puede verse que el modelo propuesto consigue la mejor tasa de reconocimiento eso es importante por que muestra que usar redes complejas se presentan como una solución promisoría en el area de reconocimiento de patrones.

Extractor de Características	Nro. de características	Nro. de imágenes correctas	Porcentaje % Acierto
Filtros de Gabor	48	994	95.94
Momentos de Hu	7	594	57.33
Histograma	17	869	83.88
Geometrico GLCM	8	971	93.72
GLCM	22	943	91.02
$K = 2$ Gabor	96	980	94.59
$K = 3$ Gabor	144	995	96.04
Contornos Red Compleja	390	1015	97.97
Textura Red Compleja	336	945	91.21
Modelo Propuesto	441	1023	98.74

Tabla 5.6: Comparación de los resultados para diferentes parámetros del modelo propuesto.

Es importante notar que los métodos basados en redes complejas tanto el método propuesto como el método basado en contornos son los que mejores resultados ha obtenido, es por ese motivo que mostraremos detalles del proceso de clasificación para eso usaremos las matrices de

confusion de dichos extractores como se puede ver en la tabla 5.7 se pueden ver los resultados del modelo propuesto 5.7 y en la tabla 5.8 los resultados del modelo basado en contornos. Como se puede ver en la figura 5.7 los parásitos 2 y 3 tienen algo de semejanza en forma con otros parásitos, pero en textura son diferentes, en ese sentido es importante notar que el modelo propuesto no cometió error en esos casos. Sin embargo el modelo basado en contornos consiguió separar correctamente la clase 7; sin embargo el modelo cometió errores con las clases 1 y 4.

	1	2	3	4	5	6	7	8	Co(%)
1	98.77						1.23		1.2
2		100							
3			100						
4				97.30	2.70				2.70
5	0.61			1.22	97.56		0.61		2.44
6					1.30	98.70			1.3
7	0.39			0.39			99.22		0.78
8				1.43				98.57	1.43
Om(%)	1.0			3.04	4.0		1.8		98.74

Tabla 5.7: Matriz de confusion, con sus respectivos error por cada clase de la clasificación del método propuesto a los 8 especies de parásitos helmintos.

En resumen, los resultados obtenidos son muy alentadores en el sentido de que las redes complejas si se pueden usar para el reconocimiento de patrones uní y bí dimensionales, posibilitando resolver problemas reales como el diagnóstico de especies de parásitos helmintos, los resultados demuestran que si es posible usar redes complejas para la caracterización de parásitos.




Figura 5.9: Propuesta para la clasificación de los parásitos Helmintos




Figura 5.10: Contornos externos e internos de los diferentes parásitos

	1	2	3	4	5	6	7	8	Co(%)
1	96.30			2.70	1.22	0.87			1.2
2	1.23	98.04	0.94		3.05				0
3			98.11					1.43	0
4	1.23			95.95		0.43			2.7
5	1.23	1.96		1.35	95.73	0.43			2.4
6						98.27			1.3
7							100		0.8
8			0.94					98.57	0
Om(%)	3.70	1.96	1.89	4.05	4.27	1.73		1.43	98.7

Tabla 5.8: Matriz de confusion, cons sus respectivos error por cada clase, para el modelo basado en contornos.




Figura 5.11: Imagen micrográfica del parásito también se puede ver su visualización en 3D, y dos redes generadas para dos parametros distintos cuando la distancia vale 4 y cuando vale 6




Figura 5.12: Enterobius Vermiculares con problemas de transformaciones geométricas, se puede ver que su vector de características para las diferentes transformaciones geométricas son muy parecidas eso hace al método robusto ante problemas de rotación y escala, (a) Reducida de tamaño al 50% del tamaño original, (b) Imagen Original, (c) Aumentada de tamaño al 150 %, (d) Imagen rotada y aumentada 150 %, (e) Imagen normal rotada, (f) Imagen rotada y disminuida de tamaño




Figura 5.13: Análisis de las variables canónicas se pueden ver la combinación de la 8va variable combinada con la 7ma, 6ta, 5ta, 4ta, 3ra, 2da, 1ra. Y 3ra combinada con las variables 2da, 1ra




Figura 5.14: Visualización de la variable 7ma con la 6ta, 5ta, 4ta, 2da, 1ra variable. También vemos la 4ta y 3ra, 2da, 1ra. Además la 6ta combinada con 5ta, 4ta, 2da, 1ra finalmente la 5ta variable combinada con 4ta, 3ra, 2da, 1ra

Conclusiones

6.1 Discusión sobre el modelos propuesto

Es importante tener en cuenta algunos aspectos que hacen que esta propuesta sea innovadora en referencia a los modelos existentes

- La idea de esta propuesta es innovadora ya que según se revisaron los trabajos relacionados no son similares al modelo propuesto, a pesar de ser una idea sencilla en su concepción demostró ser potente para extracción de características de series temporales e imágenes.
- En cuanto a las series temporales la mayoría de los trabajos buscan representar redes complejas enfocadas preservar las características de la naturaleza de la serie características como aleatoriedad en caso de series aleatorias, así como periodicidad buscando correlaciones y ciclos repetidos o pseudo repetidos para la creación de las mismas, e incluso hay técnicas para preservar sus comportamiento de dinámicas complejas como lo es el comportamiento caótico.
- En cuanto a la generalidad del modelo se puede notar que ya sea bidimensional o tridimensional el modelo sería extensible a una dimensión mayor, por ejemplo si se tuviera una base de datos de imágenes 3D donde se tiene el concepto de voxel el cual tiene una posición 3D x, y, z además de tener un valor de intensidad (color) asociado entonces la propuesta de modelamiento sería la misma ya que cada nodo de la red sería la posición

4D x, y, z, I y la conectividad de la misma estará dada por distancia entre sus vertices para diferentes umbrales y así crear diferentes redes.

- Para el caso de modelos para imágenes la propuesta presenta una ventaja clara ya que normalmente se intenta resaltar características por separado de las imágenes, como lo es la forma y la textura proponiendo modelos por separado sin embargo podemos ver que en la propuesta cuando los niveles de distancia (Umbral) entre nodos es baja la forma de las estructuras ya sean internas o externas son resaltadas y cuando los niveles de distancia son mayores la textura de la imagen es caracterizada, por lo tanto se puede decir que el modelo es mas completo al considerar ambos aspectos a la vez. Ahora si por el contrario se quisiese resaltar uno de los aspectos mas que otro (forma o textura), el modelo debería ajustar el calculo de la distancia dando mayor valor al parámetro alfa o beta.
- El modelo propuesto para imágenes fue probado solo para imágenes en niveles de grises si se quiere extender a color el modelo seria extensible de forma natural, ya que la posición de un nodo seria el valor x, y del pixel mas el valor del color el cual puede ser colocado en un universo de color especifico por ejemplo para el dominio $R G B$, siendo la posición final del nodo (x, y, R, G, B) y lo siguiente es calcular distancia entre los nodos usando diferentes umbrales de distancias.

6.2 Conclusiones

Como pudo ser demostrado en el capitulo de resultados las redes complejas pueden ser utilizados en el reconocimiento de patrones unidimensionales y bidimensionales, esto demuestra la potencialidad del uso de las redes complejas en la solución de problemas reales, donde se presentaron dos aplicaciones una en el reconocimiento de palabras habladas y la otra en el reconocimiento de imágenes de parásitos helmintos.

En el caso del reconocimiento de palabras habladas se demostró como una serie temporal puede ser estudiada desde el punto de vista topológico analizando sus propiedades, y usar dichas propiedades para caracterizar y diferenciar señales temporales, mostrando porcentajes altos en el reconocimiento llegando a un 99.44%, además el modelo es robusto ya que el principal parámetro (variación de los umbrales) da tasas de reconocimiento altas para diferentes valores, eso de muestra que el método no es una solución particular, por el contrario da buenos resultados para diferentes valores.

En el caso de reconocimiento de imágenes se ha demostrado que los métodos basados en redes complejas obtienen mejores resultados que técnicas tradicionales ampliamente usadas en el reconocimiento de imágenes como los son los filtros de Gabor, eso es importante ya

que la propuesta se presenta como una nueva alternativa de solución a distintos problemas de reconocimiento de imágenes

Las propuestas basadas en redes complejas, se presentan como un campo potencial de aplicación en reconocimiento de patrones en general, la idea central es ver como el patron puede ser representado como una red compleja, en ese sentido es importante que las características del patron se vean reflejados en la representación por red, además nuevas características pueden ser analizadas a partir del grafo. Un siguiente paso es ver que medida podría ser usada para caracterizar y diferenciar los diferentes patrones, en la actualidad existen muchas medidas que podrían usarse es importante hacer un análisis cuantitativo de las diferentes métricas usadas en ese sentido es importante usar una maquina de aprendizaje para poder realizar dicha selección.

6.3 Recomendaciones

Una de las cosas que es importante notar es que el tamaño del patron es una aspecto que se debe considerar ya que tanto una imagen como un sonido son muestreados a diferentes tamaños, cuando una imagen es de gran tamaño hace que el numero de cálculos necesarios para extraer el vector de características tomarían un tiempo considerable, incluso se tendría que considerar una capacidad minima de memoria para poder procesar el patron.

En las aplicaciones presentadas tanto las imágenes como el archivo de sonido son soportados por el computador pero imágenes de mayor resolución podrían desbordar la memoria. En esos casos podría usarse técnicas de disminución del tamaño original. Por ejemplo en el caso de una imagen se puede reducir el tamaño de una imagen, manteniendo las características originales de forma y textura lo cual puede ser realizado de forma perceptual observando la imagen original y sus reducciones, fue presentado en los resultados que el modelo es invariante a la transformación de escala, claro que esa escala tiene una tolerancia para el caso de los parásitos un tamaño mínimo de 50×50 pixels de resolución garantizando que el modelo presente buenos resultados.

En el caso de los archivos de sonido, es importante tomar en consideración que las grabaciones de sonido tienen intervalos de tiempo que corresponden a la palabra hablada así como intervalos de silencio que no son necesarios en el reconocimiento y que por el contrario alteran el calculo de las características, pero eso es superado usando técnicas de detección de inicio y fin de palabra, lo cual es lógico y es un paso usado también por cualquier técnica de reconocimiento de palabras habladas.

Revisando la literatura uno puede notar la existencia de diferentes propuestas en la representación de los patrones como redes complejas, eso muestra que las redes complejas presentan flexibilidad y variedad de su uso en el reconocimiento de patrones. Es importante notar que la

propuesta es original a pesar de ser una idea simple puede usarse tanto unidimensional como bidimensionalmente.

6.4 Trabajos Futuros

Diferentes aplicaciones en reconocimiento de imágenes pueden ser usadas por ejemplo en el reconocimiento de rasgos biométricos como reconocimiento de iris o de rostros, las cuales son problemas abiertos y ampliamente estudiados que ayudarían a mostrar la potencial aplicabilidad del modelo presentado además de delimitar las limitaciones del modelo lo cual es importante para aplicaciones reales.

En el caso de aplicar el modelo en el reconocimiento de palabras habladas el modelo no fue comparado otras técnicas por eso seria importante cuantificar las diferencias con métodos tradicionales para así cuantificar el desempeño real de la propuesta.

La propuesta fue probada para patrones unidimensionales y bidimensionales en ese sentido podría ser usado para patrones tridimensionales usando el concepto del voxel lo cual seria una extension natural del modelo propuesto, la diferencia entre las aplicaciones anteriores seria minima, seria interesante mostrar una aplicación en esa area que hoy en día es posible ya que varios dispositivos permiten tener patrones en esa dimension (imágenes 3D).

Referencias Bibliográficas

- Albert, R., Jeong, H., and Barabási, A. (2000). Error and attack tolerance of complex networks. *Nature*, 406(6794):378–382.
- Aldana, M. (2006). Tutorial redes complejas. Technical report, Instituto de Ciencias Físicas UNAM. <http://www.fis.unam.mx/~max/English/notasredes.pdf>.
- Aldana, M. and Cluzel, P. (2003). A natural class of robust networks. *Proceedings of the National Academy of Sciences of the United States of America*, 100(15):8710.
- Amancio, D. R., Nunes, M. G., Oliveira Jr, O. N., and Costa, L. d. F. (2012). Extractive summarization using complex networks and syntactic dependency. *Physica A: Statistical Mechanics and its Applications*, 391(4):1855–1864.
- Backes, A., Casanova, D., and Bruno, O. (2009). A complex network-based approach for boundary shape analysis. *Pattern Recognition*, 42(1):54–67.
- Backes, A., Gonçalves, W., Martinez, A., and Bruno, O. (2010). Texture analysis and classification using deterministic tourist walk. *Pattern Recognition*, 43(3):685–694.
- Backes, R. (2010). *Estudos de Metodos de Analise de complexidade em imagens*. PhD thesis, Instituto de Ciencias Matematicas e de Computacao - USP Brasil.
- Barabási, A., Albert, R., and Jeong, H. (2000). Scale-free characteristics of random networks: the topology of the world-wide web. *Physica A: Statistical Mechanics and its Applications*, 281(1-4):69–77.
- Barabasi, A. and Crandall, R. (2003). Linked the new science of networks. *American journal of Physics*, 71:409.

- Bialonski, S. (2012). Inferring complex networks from time series of dynamical systems: Pitfalls, misinterpretations, and possible solutions. *arXiv preprint arXiv:1208.0800*.
- Boccaletti, S., Latora, V., Moreno, Y., Chavez, M., and Hwang, D. (2006). Complex networks: Structure and dynamics. *Physics reports*, 424(4-5):175–308.
- Box, G., Jenkins, G., and Reinsel, G. (1976). *Time series analysis: forecasting and control*. Holden-day San Francisco.
- Campanharo, A. S., Sirer, M. I., Malmgren, R. D., Ramos, F. M., and Amaral, L. A. N. (2011). Duality between time series and networks. *PloS one*, 6(8):e23378.
- Canny, J. (1986). A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 8(6):679–698.
- Chatfield, C. (2003). *The analysis of time series: an introduction*. CRC Pr I Llc.
- Chuctaya, J., Mena, J., Humpire, G., Rodriguez, A., Beltrán, C., and Patino, R. (2010). Detec-
ción de huevos helmintos mediante plantillas dinámicas. *Conferencia Latinoamericana de Informática CLEI*, pages 1–12.
- Costa, L., Rodrigues, F., Travieso, G., and Boas, P. (2007). Characterization of complex net-
works: A survey of measurements. *Advances in Physics*, 56(1):167–242.
- Davidson, J., Grassberger, P., and Paczuski, M. (2005). Earthquake recurrence as a record
breaking process. *Arxiv preprint physics/0507082*.
- de Angelis André, F. (2005). Tutorial redes complexas. Techni-
cal report, Fundação de Amparo à Pesquisa do Estado de São Paulo.
www.ft.unicamp.br/~andre/Gerais/Tutorial_RedesComplexas.pdf.
- Dellnitz, M., Molo, M., Metzner, P., Preis, R., and Sch
"utte, C. (2006). Graph algorithms for dynamical systems. *Analysis, modeling and simulation
of multiscale problems*, pages 619–645.
- Donner, R., Hinrichs, U., and Scholz-Reiter, B. (2008). Symbolic recurrence plots: A new
quantitative framework for performance analysis of manufacturing networks. *The European
Physical Journal-Special Topics*, 164(1):85–104.
- Donner, R. V., Zou, Y., Donges, J. F., Marwan, N., and Kurths, J. (2010). Recurrence network-
sUm novel paradigm for nonlinear time series analysis. *New Journal of Physics*, 12(3):033025.
- Fabricio, A. (2010). *Aprendizado de maquina en redes complexas*. PhD thesis, Instituto de
Ciencias Matematicas e de Computacao USP Brasil.

- Ferreira, D. S., Papa, A., and Menezes, R. (2013). The small world of seismic events. *arXiv preprint arXiv:1304.4979*.
- Flint, J., Van Duynhoven, Y., Angulo, F., DeLong, S., Braun, P., Kirk, M., Scallan, E., Fitzgerald, M., Adak, G., Sockett, P., et al. (2005). Estimating the burden of acute gastroenteritis, foodborne disease, and pathogens commonly transmitted by food: an international review. *Clinical infectious diseases*, 41(5):698–704.
- Franses, P. and Van Dijk, D. (2000). *Nonlinear time series models in empirical finance*. Cambridge Univ Pr.
- Hidalgo, C. (2010). *The value in the links: Networks and the evolution of organizations*. Natural Science of Networks.
- Hirata, Y., Horai, S., and Aihara, K. (2008). Reproduction of distance matrices and original time series from recurrence plots and their applications. *The European Physical Journal Special Topics*, 164(1):13–22.
- Hu, M. (1962). Visual pattern recognition by moment invariants. *Information Theory, IRE Transactions on*, 8(2):179–187.
- Humpire, G., Chuctaya, J. and Gutierrez, J. C., Bruno, O., and Beltrán, C. (2011). Detección de huevos helmintos mediante plantillas dinámicas. *Visão Computacional em Bioinformática*.
- Keeling, M. and Eames, K. (2005). Networks and epidemic models. *Journal of the Royal Society Interface*, 2(4):295.
- Keogh, E., Chu, S., Hart, D., and Pazzani, M. (2004). *Segmenting time series: A survey and novel approach*. World Scientific Publishing.
- Kim, H. and Kim, J. (2005). Cyclic topology in complex networks. *Arxiv preprint physics/0503168*.
- Kurita, T., Otsu, N., and Abdelmalek, N. (1992). Maximum likelihood thresholding based on population mixture models. *Pattern Recognition*, 25(10):1231–1240.
- Lacasa, L., Luque, B., Ballesteros, F., Luque, J., and Nuño, J. C. (2008). From time series to complex networks: The visibility graph. *Proceedings of the National Academy of Sciences*, 105(13):4972–4975.
- Lam, S. (1996). Texture feature extraction using gray level gradient based co-occurrence matrices. In *Systems, Man, and Cybernetics, 1996., IEEE International Conference on*, volume 1, pages 267–271. IEEE.

- Latora, V. and Marchiori, M. (2001). Efficient behavior of small-world networks. *Physical Review Letters*, 87(19):198701.
- Liao, W. et al. (2005). Clustering of time series data—a survey. *Pattern Recognition*, 38(11):1857–1874.
- Lin, C. and Lin, W. (2011). Image retrieval system based on adaptive color histogram and texture features. *The Computer Journal*, 54(7):1136–1147.
- Luque, B., Lacasa, L., Ballesteros, F., and Luque, J. (2009). Horizontal visibility graphs: Exact results for random time series. *Physical Review E*, 80(4):046103.
- Marina, M. J. and Carlos, G. C. J. (2010). Modelamiento de red compleja para el análisis de comunidades en twitter. *Proceedings, CSPC-2010 IX Congreso de la Sociedad Peruana de Computación*, pages 113–122.
- Marwan, N., Donges, J., Zou, Y., Donner, R., and Kurths, J. (2009). Complex network approach for recurrence analysis of time series. *Physics Letters A*, 373(46):4246–4254.
- Newman, M. (2001). Scientific collaboration networks. i. network construction and fundamental results. *Physical review E*, 64(1):016131.
- Newman, M. (2003). The structure and function of complex networks. *SIAM review*, 45(2):167–256.
- P., E. and A., R. (1959). On random graphs. *Publicationes Mathematicae*, 6:290–297.
- Pagani, G. A. and Aiello, M. (2013). The power grid as a complex network: a survey. *Physica A: Statistical Mechanics and its Applications*.
- Pardo, T., Antigueira, L., das Gracas Nunes, M., Oliveira, O., and da Fontoura Costa, L. (2006). Using complex networks for language processing: The case of summary evaluation. In *Communications, Circuits and Systems Proceedings, 2006 International Conference on*, volume 4, pages 2678–2682. IEEE.
- Parker, J. (2010). *Algorithms for image processing and computer vision*. Wiley.
- Ravasz, E. and Barabási, A. (2003). Hierarchical organization in complex networks. *Physical Review E*, 67(2):026112.
- Reijneveld, J., Ponten, S., Berendse, H., and Stam, C. (2007). The application of graph theoretical analysis to complex networks in the brain. *Clinical Neurophysiology*, 118(11):2317–2331.

- Rubinov, M. and Sporns, O. (2010). Complex network measures of brain connectivity: uses and interpretations. *Neuroimage*, 52(3):1059–1069.
- Salas, J. and Delleur, J. (1980). *Applied modeling of hydrologic time series*. Water Resources Publication.
- Tan, H., Gelfand, S., and Delp, E. (1989). A comparative cost function approach to edge detection. *Systems, Man and Cybernetics, IEEE Transactions on*, 19(6):1337–1349.
- Vapnik, V. (2000). *The nature of statistical learning theory*. Springer-Verlag New York Inc.
- Wang, D. (2011). Multifractal characterisation and analysis of complex networks.
- Watts, D. and Strogatz, S. (1998a). Collective dynamics of small-world networks. *nature*, 393(6684):440–442.
- Watts, D. and Strogatz, S. (1998b). Small world. *Nature*, 393:440–442.
- Wesley, N. (2010). *Caminhadas determinísticas em redes complexas, aplicada em visão computacional*. PhD thesis, Instituto de Ciencias Matemáticas e de Computação - USP Brasil.
- Xu, X., Zhang, J., and Small, M. (2008). Superfamily phenomena and motifs of networks induced from time series. *Proceedings of the National Academy of Sciences*, 105(50):19601–19605.
- Yang, Y. and Yang, H. (2008). Complex network-based time series analysis. *Physica A: Statistical Mechanics and its Applications*, 387(5-6):1381–1386.
- Zhang, J. (2007). Detecting and describing pseudo-periodic dynamics from time series.
- Zhang, J. and Small, M. (2006). Complex network from pseudoperiodic time series: Topology versus dynamics. *Physical review letters*, 96(23):238701.
- Zhang, J., Sun, J., Luo, X., Zhang, K., Nakamura, T., and Small, M. (2008). Characterizing pseudoperiodic time series through the complex network approach. *Physica D: Nonlinear Phenomena*, 237(22):2856–2865.