



TECNOLÓGICO DE ESTUDIOS SUPERIORES DE ECATEPEC

División De Ingeniería En Sistemas Computacionales

“ENTRENAMIENTO DE UNA RNA CON PROCESAMIENTO DENDRAL PARA
CLASIFICAR EL NIVEL DE DISMORFIA FACIAL”

T E S I S

QUE PARA OBTENER EL GRADO DE INGENIERO EN
SISTEMAS COMPUTACIONALES

P R E S E N T A N :

Diana López Rangel

Itzel Joanna Saldívar Medina

Director: Dra. Griselda Cortés Barrera

Codirector: Dra. Mercedes Flores Flores

Revisor Metodológico: M. en C. Xóchitl Raquel Wong Cohén

Asesor externo: Dra. Fabiola Miroslava Villalobos Castaldi

Índice General

ÍNDICE DE TABLAS.....	IV
ÍNDICE DE FIGURAS	IV
ÍNDICE DE GRÁFICAS.....	V
CAPÍTULO 1 INTRODUCCIÓN.....	1
1.1 PLANTEAMIENTO DEL PROBLEMA	3
1.2 JUSTIFICACIÓN.....	4
1.3 ALCANCES Y LIMITACIONES.....	5
1.4 OBJETIVOS	5
1.4.1 <i>General</i>	5
1.4.2 <i>Específicos</i>	5
1.5 ANTECEDENTES.....	6
1.6 ESTADO DE ARTE.....	11
1.6.1 <i>Análisis del estado de arte</i>	14
1.7 ESTRUCTURA DE LA TESIS.....	16
1.8 CONCLUSIONES DEL CAPÍTULO	16
CAPÍTULO 2 MARCO CONCEPTUAL	17
2.1 RECONOCIMIENTO DE IMÁGENES U OBJETOS EN ENTORNOS NO CONTROLADOS	18
2.2 ILUMINACIÓN Y OCLUSIONES	19
2.2.1 <i>Resolución de la imagen</i>	20
2.2.2 <i>Formatos de imágenes</i>	21
2.3 RECONOCIMIENTO DE ROSTROS	22
2.4 MODO IDENTIFICACIÓN.....	23
2.5 MODO VERIFICACIÓN.....	24
2.5.1 <i>Localización de puntos característicos de la cara</i>	24
2.6 MÉTODOS PARA EL RECONOCIMIENTO Y CLASIFICACIÓN DE IMÁGENES U OBJETOS.....	24
2.6.1 <i>Reconocimiento estadístico</i>	25
2.6.2 <i>Reconocimiento sintáctico</i>	26
2.6.3 <i>Reconocimiento de imágenes utilizando Redes Neuronales</i>	26
2.7 REDES NEURONALES.....	27
2.7.1 <i>Biológicas</i>	30
2.7.2 <i>Artificiales</i>	31
2.8 SÍNDROME PEDIÁTRICO DISMORFOGÉNICO FACIAL	38
2.8.1 <i>Distrofia Acro-Osteólitica</i>	38
2.8.2 <i>Síndrome Ectrodactilia-Displasia, Ectodérmica-Fisura palatina</i>	39
2.9 CONCLUSIONES DEL CAPÍTULO	40
CAPÍTULO 3 RNA´S PARA MEDIR EL NIVEL DE DISMORFIA FACIAL EN LABIO LEPORINO	41
3.1 ALGORITMO DEL CLASIFICADOR SMO	43
3.2 ALGORITMO DEL CLASIFICADOR IBK.....	45
3.3 ALGORITMO DEL CLASIFICADOR MULTILAYER PERCEPTRON.....	47
3.4 ALGORITMO DE ENTRENAMIENTO Y EJEMPLO CON LA RNMPD	50
3.5 PREPROCESAMIENTO DE LOS DATOS CON LA RNMPD	56
3.5.1 <i>Características de las imágenes</i>	56
3.5.2 <i>Características de rasgos descriptores de la red</i>	57
3.6 OPTIMIZACIÓN Y NORMALIZACIÓN DE LOS DATOS.....	61

3.7	CONCLUSIONES DEL CAPÍTULO	64
CAPÍTULO 4	RESULTADOS	66
4.1	RESULTADOS DE LA APLICACIÓN.....	67
4.2	CARACTERÍSTICAS DE LOS CLASIFICADORES UTILIZADOS EN LA INVESTIGACIÓN CON WEKA	68
4.3	RENDIMIENTO DE LA PROPUESTA CON OTROS MÉTODOS CLASIFICADORES	72
4.4	CONCLUSIONES DEL CAPÍTULO	75
CAPÍTULO 5	CONCLUSIONES Y TRABAJOS A FUTURO.....	77
5.1	CONCLUSIONES.....	78
5.2	TRABAJOS A FUTURO.....	81
BIBLIOGRAFÍA.....		82

Figura 21 a) Detección de puntos en dismorfia	b) Detección de puntos en persona sin dismorfia	...c) Detección de puntos en persona con operación persona con dismorfia	67
Figura 22 Interfaz de Multilayer Perceptron			68
Figura 23 Interfaz Gráfica de IBK.....			70
Figura 24 Interfaz Gráfica de SMO.....			71

Índice de Gráficas

Gráfica 1 Primer escenario con 78 datos de prueba y 78 datos de entrenamiento.....	73
Gráfica 2 Segundo escenario 160 datos de prueba y 78 datos de entrenamiento.....	74
Gráfica 3 Tercer escenario 80 datos de prueba y 78 datos de entrenamiento.....	74
Gráfica 4 Cuarto escenario 80 datos de prueba y 160 datos de entrenamiento.....	75
Gráfica 5 Promedio total de los escenarios.....	75

CAPÍTULO 1 INTRODUCCIÓN

En el primer capítulo se explica de forma detallada la justificación y los objetivos del problema planteado, además se mencionan los alcances y limitaciones del mismo. En seguida se abordan los aspectos históricos del problema que se presenta en este documento, dichos antecedentes son de gran importancia para entender los capítulos posteriores. También dentro de este capítulo se citan varios trabajos de investigadores en el área, con relación a los algoritmos para extracción de rasgos característicos.

Desde los años 50's se han hecho diversas investigaciones sobre los Síndromes Pediátricos Dismorfogénicos que afectan principalmente a niños (de entre el nacimiento y los 18 años de edad) entre los síndromes más notables se encuentran: neonatales, mal desarrollo, inmunológicos, cutáneos, endocrinológicos, esqueléticos, musculares, metabólicos, faciales, cardíacos y pulmonares, digestivos, renales, hematológicos, oculares, neurológicos, cromosómicos, anomaladas y ambientales; estos, son considerado de gran interés en el cuidado clínico y salud pública [1]. Una de las primeras publicaciones sobre enfermedades cutáneas fue la de Van Bogaert y Hozay en 1953, en la cual dan a conocer la Distrofia Acro-Osteólítica (Acro-osteólisis no mutilante con dismorfia facial), esta inicia a temprana edad con inhibición del desarrollo en zonas acras de los miembros, con rasgos característicos: chatos, de raíz nasal aplanada, pómulos prominentes y mejillas abultadas, orejas deformes; alopecia de cejas, barba lampiña, micrognatia, entre otras anomalías en la piel, ojos y cerebrales [2]. En 1961, Roselly y Gulianetti publica sobre el síndrome Ectrodactilia-Displasia, Ectodermica-Fisura palatina; los rasgos que preservan en este tipo de enfermedad es: hipoplasia facial media, prominencia del puente nasal, manos y pies en pinzas, hiperpigmentación difusa, fisura labio paladina con labio leporino doble y fisura completa del paladar, entre otras anomalías ocasionales [3].

Actualmente, aproximadamente el 3% de niños recién nacidos tienen un tipo de malformación, estas enfermedades son diagnosticadas clínicamente y exploradas fisiopatológicamente dentro de los Síndromes Pediátricos de Distrofia Facial, debido a los patrones faciales característicos y clínicos muy peculiares: leves (cara redonda y plana con amplia base nasal, entre otras anomalías) y graves (la cara es una reminiscencia de la displasia frontonasal con edad adulta existente en plenitud cada vez mayor de los rasgos faciales, entre otras anomalías) obtenidos a partir de la exploración física correspondiente a un tipo de enfermedad en particular, lo que permite una mejor comprensión para su estudio y su posible corrección quirúrgica [4].

Al igual que los seres humanos, las disciplinas de la Inteligencia Artificial (IA) han contribuido en gran manera a la interpretación de imágenes médicas mediante un sistema informático, y han sido de gran apoyo a médicos expertos (Psicólogos, Psiquiatras, Cirujanos, entre otros) en diversos problemas complejos de las diversas áreas de la medicina [5]. Dentro de las aplicaciones de la IA surge la visión artificial, la cual permite la captura, almacenamiento, y manipulación de imágenes digitales y así reconocer información visual (patrones generales). Una de las ramas de la IA son las "Redes

Neuronales Artificiales”, éstas son un paradigma de aprendizaje y procesamiento automático inspirado en el comportamiento del sistema nervioso, simulando la interconexión de los sistemas neuronales biológicos [6].

La Red Neuronal Morfológica con Procesamiento en las Dendritas (RNMPD) ha sido una de las RNA´s más utilizada recientemente en el campo de Reconocimiento de Patrones. La teoría de este tipo de RNA ha sido satisfactoriamente aplicada en una variedad de problemas relacionados con este campo y en la segmentación de imágenes. Además, las RNMPD han igualado y en ocasiones superado el rendimiento de otro tipo de RNA [7].

Tomando en consideración lo mencionado anteriormente, se propone la realización de este proyecto para profundizar en el uso de técnicas de aprendizaje automático, diseñar y validar el rendimiento y comportamiento de la RNMPD donde los rasgos físicos característicos de los Síndromes Pediátricos de Distrofia Facial (Distrofia Acro-Osteólitica y síndrome Ectrodactilia-Displasia, Ectodermica-Fisura palatina), serán considerados como patrones de entrada y servirán para entrenar la RNMPD y así clasificar el tipo de Dismorfia Facial que se evalúa.

1.1 Planteamiento del problema

Un paciente pediátrico dismórfico presenta rasgos faciales o un patrón de malformaciones congénitas que, en su conjunto, son diferentes de los considerados normales para la población general. En ocasiones, estos rasgos o anomalías pueden encontrarse agrupados en una asociación reconocible, como un síndrome concreto o un proceso debido a una causa específica que puede alterar o arrojar resultados erróneos en este tipo de sistemas [8].

Los sistemas de reconocimiento facial tienen la ventaja de ser rápidos, precisos y económicos cuando están en condiciones controladas; sin embargo en condiciones no controladas se enfrentan con diferentes problemas relacionados con los datos a analizar como las variaciones de escala, de orientación, expresión facial, o la detección de dismorfias faciales, ya que el rostro humano no es del todo simétrico, pero existen ciertas asimetrías, consideradas normales [9].

A pesar de que este tipo de tecnología está avanzando de manera significativa, aun no hay un sistema de reconocimiento facial que sea totalmente funcional y confiable. Un ejemplo de ello son los sistemas de reconocimiento de emociones mediante las

expresiones faciales, que han estado utilizando psiquiatras y psicólogos para poder detectar y medicar los problemas de salud mental que se presentan con mayor frecuencia (trastornos de ansiedad, trastornos mentales inducidos por una sustancia y los trastornos del estado de ánimo, como la depresión), pero en el proceso se presentan diversas fallas, debido a que el sistema no reconoce a pacientes que usen lentes, barba, bigote o aquellos que tienen algún problema en los músculos del rostro como parálisis facial [10]. Tomando en consideración lo mencionado anteriormente, se propone la realización de este proyecto para profundizar en el uso de técnicas de aprendizaje automático, diseñar y validar el rendimiento y comportamiento de la RNA Morfológica con procesamiento Dendral donde los rasgos físicos característicos de los Síndromes Pediátricos de Dismorfia Facial (Distrofia Acro-Osteólitica y síndrome Ectrodactilia-Displasia, Ectodermica-Fisura palatina), serán considerados patrones de entrada y servirán para entrenar dicha red y así clasificar el tipo de Dismorfia Facial que se evalúa.

1.2 Justificación

El proyecto tiene un gran impacto en el sector salud, ya que está enfocado principalmente para beneficio de doctores y especialistas de diversas áreas como dermatología, cirugía maxilofacial y cirugía plástica [11]. Los algoritmos de reconocimiento facial, permiten conocer el grado de asimetría que presenta la cara de un paciente (ojos, nariz, boca, cejas) para dar una mejor atención y valoración de su caso.

Debido a la necesidad de aportar en uno de los proyectos críticos para avanzar en el campo de la medicina y tomando en cuenta que, en la literatura no se han utilizado las Redes Neuronales Artificiales para imágenes de personas con Dismorfia Facial; este proyecto servirá para abordar esta necesidad clínica, y así recolectar y organizar los datos de rasgos físicos faciales característicos del tipo de Distrofia Facial (Ectodermica-Fisura palatina, Ectrodactilia-Displasia o Acro-Osteólitica), a través del entrenamiento de una RNMPD.

La trascendencia de esta tesis radica en demostrar la eficiencia, y el rendimiento de la RNMPD propuesta, la cual será comparada con diferentes métodos clasificadores tales como: IBK, SMO Y Multilayer Perceptron.

1.3 Alcances y limitaciones

Los alcances del proyecto, en primera instancia es proporcionar a investigadores en el área (informática, sistemas, robótica, etc.) y especialistas (psicólogos, psiquiatras y cirujanos) un modelo que auxilie a determinar con mayor precisión el tipo de dismorfia facial (Ectodermica-Fisura palatina, Ectrodactilia-Displasia o Acro-Osteólitica), que presenta una persona. Así mismo, se desea destacar el comportamiento de la RNMPD ante problemas (dismorfia facial) del área de medicina (psicología psiquiatría y cirugías) y coadyuvar al área de informática o sistemas computacionales en el desarrollo de un algoritmo eficiente utilizando este tipo de red para la implementación de una aplicación móvil que permita identificar el tipo de dismorfia.

Por otro lado, la limitación más grande a la que se enfrenta el proyecto es que existe un número limitado de personas con problemas de dismorfia facial, lo que ocasiona su difícil acceso a bases de datos con imágenes de esta problemática.

1.4 Objetivos

A continuación se presenta el objetivo general y los objetivos específicos que se quieren llevar a cabo para este proyecto.

1.4.1 General

Entrenar una Red Neuronal Morfológica con Procesamiento en sus Dendritas para clasificar el nivel de Dismorfia Facial que se evalúa (Distrofia Acro-Osteólitica y síndrome Ectrodactilia-Displasia, Ectodermica-Fisura palatina).

1.4.2 Específicos

- Analizar e interpretar los diferentes Síndromes Pediátricos de Distrofia Facial.
- Recopilar imágenes de pacientes con y sin enfermedades de Dismorfia Facial.
- Identificar y extraer los rasgos físicos faciales estratégicos de las imágenes digitales.
- Entrenar y probar la RNMPD, para conocer su comportamiento ante el Síndrome Pediátrico de Distrofia Facial.
- Comparar el desempeño de la RNMPD con otros métodos clasificadores.

1.5 Antecedentes

Las dismorfias faciales tienen su origen hace algunos siglos, en algunas culturas se suponía que las mujeres que daban a luz a criaturas con algún tipo de dismorfia habían tenido tratos con el diablo o con otros espíritus malignos. Las primeras representaciones artísticas de fetos malformados guardan tal exactitud anatómica que con frecuencia es posible diagnosticar afecciones o síndromes específicos a partir de ellas [12].

En la Edad Media, las representaciones de las malformaciones eran mucho más imaginativas y eran frecuentes las representaciones de éstas como híbridos de seres humanos y animales. Esta información guarda un profundo sentido simbólico de las deformaciones congénitas del cuerpo humano, como de las modificaciones culturales del mismo, lo que impulsa estructurar paralelos entre la teratología y la antropología. Al respecto, se corroboran las representaciones, a partir del arte, de algunas malformaciones congénitas del cuerpo humano, cuyos fines son simbólicos dentro del sistema de la cultura. De ahí que los estudios de la paleopatología han dado a conocer “aspectos imprevistos del pensamiento primitivo en relación con las enfermedades y la medicina, y lo que es de mayor utilidad y aplicación más general, son las lesiones que tienen significado cultural” [13].

A través del significado cultural de las malformaciones congénitas del cuerpo, se pueden conocer creencias, costumbres, oficios de la época y hasta rastrear interrelaciones humanas. Carlson, manifiesta que al comienzo del siglo XIX Étienne Geoffroy de Saint Hilaire acuñó el término teratología, que literalmente describe la ciencia que estudia las malformaciones congénitas [4]. Al final del mismo siglo, el análisis científico de la teratología se asentó sobre bases más sólidas, gracias a la publicación de varios tratados enciclopédicos que cubrieron de forma exhaustiva los aspectos anatómicos de las malformaciones congénitas. Con el desarrollo de la embriología experimental y la genética a principios del siglo XX, los investigadores comenzaron a producir anomalías congénitas específicas mediante manipulaciones genéticas o embriológicas en animales de experimentación, lo cual condujo a la desmitificación de las anomalías congénitas y a la búsqueda de explicaciones racionales y científicas para estos defectos. A pesar de esto,

las viejas creencias están muy arraigadas y aún hoy los pacientes tienden a creer en muchas de ellas [14].

La cabeza y por consiguiente el rostro, han sido el principal elemento constitutivo de la imagen corporal, y los huesos frontal y occipital han sido los más susceptibles de modificación para darle a la cabeza la forma establecida y deseada en el grupo [15]. Al hablar de identidad e imagen corporal, Aguado, manifiesta que en múltiples ocasiones ha sido cuestionado el concepto de identidad y se ha mencionado que incluso es un concepto que encubre una realidad social de clase, o simplemente que es irrelevante para las ciencias sociales. Sin embargo, si tratamos de sustantivar la identidad como una determinada esencia del ser, ciertamente reeditaríamos las discusiones filosóficas sobre el ser y tal vez nos perderíamos al tratar de investigar un fenómeno social. Sin embargo, la identidad como el conjunto de evidencias sobre el sí mismo, es particularmente útil para comprender los procesos ideológico-culturales. Esta evidencia primordial se estructura en, por medio y a partir del cuerpo humano, en su profunda funcionalidad orgánica, su sensibilidad y su significado [16].

Actualmente, con técnicas adecuadas a cada malformación es posible corregir estos problemas para que pasen más desapercibidos en la vida social ya que los problemas relacionados con las malformaciones de órbitas, frente, nariz, boca, etc. son una parte, aunque de escasa incidencia, de mucha importancia para los pacientes que presentan esta patología y para los doctores (principalmente cirujanos) que atienden dichos casos [8]. Por situaciones como las planteadas anteriormente es que los humanos utilizan los rostros para reconocer individuos y los avances en las capacidades de computación en las últimas décadas, ahora permiten reconocimientos en forma automática [17].

Las primeras explicaciones teóricas sobre el cerebro y el pensamiento fueron dadas por Platón (427-347 a.C.) y Aristóteles (348-422 a.C.). Las mismas ideas también las mantuvieron Descartes (1569-1650) y los filósofos empiristas del siglo XVIII. La clase de las llamadas máquinas cibernéticas, a la cual la computación neuronal pertenece, tiene más historia de la que se cree: Herón (100 a.C.) construyó un autómata hidráulico [18].

En 1936 Alan Turing fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación. Sin embargo, los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, quienes, en 1943, lanzaron una teoría acerca de la forma de trabajar de las neuronas (Un Cálculo Lógico de la Inminente Idea de la Actividad Nerviosa - Boletín de Matemática Biofísica 5: 115-133). Ellos modelaron una red neuronal simple mediante circuitos eléctricos [19].

Una década después (en 1949) Donald Hebb escribió un importante libro: La organización del comportamiento, en el que se establece una conexión entre psicología y fisiología. Fue el primero en explicar los procesos del aprendizaje (que es el elemento básico de la inteligencia humana) desde un punto de vista psicológico, desarrollando una regla de como el aprendizaje ocurría. Aun hoy, este es el fundamento de la mayoría de las funciones de aprendizaje que pueden hallarse en una red neuronal. Su idea fue que el aprendizaje ocurría cuando ciertos cambios en una neurona eran activados. También intentó encontrar semejanzas entre el aprendizaje y la actividad nerviosa. Los trabajos de Hebb formaron las bases de la Teoría de las Redes Neuronales [20].

Para 1950, Karl Lashley en sus series de ensayos, encontró que la información no era almacenada en forma centralizada en el cerebro sino que era distribuida encima de él. Sin embargo, fue hasta 1957 que Frank Rosenblatt comenzó el desarrollo del Perceptrón. Esta es la red neuronal más antigua; utilizándose hoy en día para aplicación como reconocedor de patrones. Este modelo era capaz de generalizar, es decir, después de haber aprendido una serie de patrones podía reconocer otros similares, aunque no se le hubiesen presentado anteriormente. Sin embargo, tenía una serie de limitaciones, por ejemplo, su incapacidad para resolver el problema de la función OR-exclusiva y, en general, era incapaz de clasificar clases no separables linealmente. En 1959, escribió el libro Principios de Neurodinámica, en el que confirmó que, bajo ciertas condiciones, el aprendizaje del Perceptrón convergía hacia un estado finito (Teorema de Convergencia del Perceptrón) [21].

Años más tarde, Bernard Widrow y Marcial Hoff desarrollaron el modelo Adaline (ADAPtative LINear Elements). Esta fue la primera red neuronal aplicada a un problema

real (filtros adaptativos para eliminar ecos en las líneas telefónicas) que se ha utilizado comercialmente durante varias décadas [22].

En 1967 Stephen Grossberg a partir de sus conocimientos fisiológicos, escribió numerosos libros y desarrolló el modelo de redes neuronales. Realizó una red: Avalancha, que consistía en elementos discretos con actividad que varía en el tiempo que satisface ecuaciones diferenciales continuas, para resolver actividades como reconocimiento continuo de habla y aprendizaje de los brazos de un robot [23].

Un par de años después surgieron críticas que frenaron, hasta 1982, el crecimiento que estaban experimentando las investigaciones sobre redes neuronales. Minsky y Papera, del Instituto Tecnológico de Massachussets (MIT), publicaron un libro Perceptrons. Probaron (matemáticamente) que el Perceptrón no era capaz de resolver problemas relativamente fáciles, tales como el aprendizaje de una función no-lineal. Esto demostró que el Perceptrón era muy débil, dado que las funciones no-lineales son extensamente empleadas en computación y en los problemas del mundo real. A pesar del libro, algunos investigadores continuaron su trabajo. Tal fue el caso de James Anderson, que desarrolló un modelo lineal, llamado Asociador Lineal, que consistía en unos elementos integradores lineales (neuronas) que sumaban sus entradas. Este modelo se basa en el principio de que las conexiones entre neuronas son reforzadas cada vez que son activadas. Anderson diseñó una potente extensión del Asociador Lineal, llamada Brain State in a Box (BSB) [13].

En la década de los 70's Paul Werbos desarrolló la idea básica del algoritmo de aprendizaje de propagación hacia atrás (backpropagation) y Stephen Grossberg desarrollo la Teoría de Resonancia Adaptada (TRA que es una arquitectura de red que se diferencia de todas las demás previamente inventadas. La misma simula otras habilidades del cerebro: memoria a largo y corto plazo [24].

Kunihiko Fukushima en 1980 desarrolló un modelo neuronal para el reconocimiento de patrones visuales. Y más tarde John Hopfield provocó el renacimiento de las redes neuronales con su libro: "Computación neuronal de decisiones en problemas de optimización" [25].

David Rumelhart y G. Hinton redescubrieron el algoritmo de aprendizaje de propagación hacia atrás (backpropagation). A partir de 1986, el panorama fue alentador con respecto a las investigaciones y el desarrollo de las redes neuronales. En la actualidad, son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen (sobre todo en el área de control) y las empresas que lanzan al mercado productos nuevos, tanto hardware como software (sobre todo para simulación) [26].

Recientemente se ha encontrado que el procesamiento de la información ocurre también en las dendritas y no sólo en el cuerpo de las neuronas. Esto podría ser una explicación a la eficiencia del sistema nervioso, puesto que el procesamiento de la información ocurre prácticamente sobre el canal de comunicación. Lo anterior, junto con el paradigma morfológico, forma el punto de partida de la investigación reportada en este capítulo. En particular, aquí se presenta, por un lado, algunos aspectos geométricos del procesamiento dendral morfológico que permiten fácilmente visualizar las regiones de clasificación y tener una perspectiva intuitiva del proceso de producción y entrenamiento de la red. Por otro lado, y tomando como base la metodología geométrica mencionada, se propone un algoritmo de entrenamiento del perceptrón morfológico que en varios aspectos mejora al descrito. Una red neuronal se puede concebir como un mapeo no lineal entre dos espacios de patrones. Normalmente, los parámetros internos de este mapeo se determinan por un proceso de entrenamiento y son denominados en la mayoría de los casos pesos sinápticos [27].

Las RNA emplean algoritmos de aprendizaje, usualmente de tipo supervisado, donde es necesario preestablecer los nodos de salida; estos son controlados para dar un resultado deseado. Para esto se designa un supervisor o maestro que ajusta los pesos según las necesidades; el algoritmo más utilizado es el de retro propagación (backpropagation), el cual calcula la diferencia entre la salida obtenida y la salida deseada, con el fin de reducir el rango de error a través de un descenso de gradiente. Si el error es muy grande, el algoritmo devuelve la información al inicio y el maestro ajusta los pesos hasta que el error sea menor de un nivel preestablecido, cuando esto ocurre se determina que la red ha aprendido la información de entrada [28]. Las RNA utilizan parámetros como la tasa de aprendizaje (learning rate) donde se determina cuánto se cambian los pesos en cada paso, y el impulso (momentum) donde se adiciona una fracción del peso anterior al actual.

Existen métodos de evaluación de la red, uno de éstos se denomina validación por partición (split validation), donde la parte de entrenamiento usa un porcentaje de la muestra y el otro porcentaje es usado para probar el sistema; esto se determina de manera aleatoria para asegurar que la muestra de entrenamiento no hará parte de la muestra de prueba. En el artículo de Tania Camila Niño Sandoval se utilizaron redes neuronales artificiales para predecir la morfología mandibular a través de variables craneomaxilares, desde una vista posterior, permitiendo la robustez del análisis con una alta dimensionalidad de una forma rápida y económica [29].

1.6 Estado de arte

W. Castrillon, D. Álvarez y A. López llegaron a la conclusión de extraer características faciales para distinguir entre los dos tipos: las transitorias y las no transitorias. Entre las no transitorias se encuentran los ojos, las cejas y la boca, y a diferencia de las primeras siempre están presentes en las expresiones faciales. Todo esto expuesto en su tesis “Técnicas de extracción de características en imágenes para el reconocimiento de expresiones faciales” publicado en el año 2008. Para demostrarlo fue necesaria la utilización de la Transformada Wavelet de enteros a enteros y la Transformada Gabor en funcionamiento en tiempo real usando los métodos diferencial y de flujo Óptico resolviendo el objetivo de realizar una buena extracción de características faciales presentando diferentes técnicas y comparando cada método utilizado [5].

En el año 2013 P. García en su tesis titulada “Reconocimiento de imágenes utilizando redes neuronales artificiales” presenta la necesidad de desarrollar aplicaciones para teléfonos móviles que sean capaces de identificar imágenes de una forma rápida y sin consumo excesivo de recursos. Su principal objetivo era Desarrollar un sistema capaz de funcionar en modo local, sin una conexión permanente con el servidor, utilizando herramientas como OpenCV, Visual Studio con C++ y un Servidor IIS. Implementando técnicas de análisis de componentes principales y redes Neuronales backpropagation obteniendo como resultado un sistema capaz de identificar las imágenes que se capturan en buenas condiciones, consiguiendo demostrar que la infraestructura creada era adecuada para el propósito de la investigación [8] .

En la tesis “Reconocimiento Facial Basado en Puntos Característicos de la Cara en entornos no controlados” realizada por L. Blázquez en el año 2013 se presenta la problemática de realizar un sistema que compruebe la validez de sistemas comerciales basados en el marcado de puntos característicos de la cara, y que en caso de fallo los corrija de forma fiable. Con el objetivo de segmentar la cara y realizar el análisis exhaustivo de cada uno de los rasgos faciales extraídos, el autor utilizó la metodología de correspondencia entre agrupaciones de grafos elásticos (Elastic Bunch Graph Matching, EBGM) y el modelo de apariencia activa (AAM), para obtener como resultado la incorporación de varios vectores con características de diferentes poses para crear los modelos de entrenamiento y una forma de superar la falta de robustez frente a la variabilidad de pose entre los datos de entrenamiento y de test [30].

A. Morelli y S. padovani basándose en diversos algoritmos como Boosting, Cascada de clasificadores fuertes, y de Viola Jones, estudiaron el reconocimiento de las personas a través de sus rostros en la tesis “Detección y Reconocimiento de caras” donde el principal objetivo fue reconocer los rostros presentes en una imagen para posteriormente reconocerlos, apoyándose de diversos dispositivos con capacidad de procesamiento limitada, es decir, una cámara de fotos o un celular. De acuerdo a la metodología desarrollada se llegó a la conclusión de que los métodos de detección y reconocimiento pueden utilizarse en forma conjunta y automática cuando las caras de las imágenes no se encuentran ocluidas [31].

En el artículo “Un Proceso de Aprendizaje para Reconocimiento de Objetos en Línea en Tareas Robotizadas” de M. Peña del año 2013 se describe que los sistemas de visión deben ser capaces de ver y percibir objetos e imágenes quizá los más parecido a como lo hace el ser humano. Esta apreciación ha llevado a los investigadores a considerar y estudiar el diseño de sistemas de visión artificiales con una apreciación orientada a la Morfología Neuronal de los Sistemas Biológicos de Visión Humana. Dicho artículo propone mostrar un método que considere el diseño de un sistema de visión robusto, en aplicaciones de tiempo real en tareas de manufactura y ensamble con sistemas robotizados, esto con la finalidad de Mejorar el desempeño de tareas de ensamble con robots industriales que trabajan en ambientes no estructurados, utilizando percepción visual y nuevas técnicas de aprendizaje.. Para lograr su objetivo fue necesario recurrir al

método paradigma señal-símbolo y apoyarse de una red neuronal artificial del tipo FuzzyARTMAP [32].

Los investigadores del CINVESTAV de Guadalajara, Caro- Contreras y Mendez, en 2013 presentaron un nuevo algoritmo al que nombraron PIRA, esto con la finalidad de calcular Retículas de Conceptos utilizando una RNMPD. En dicha investigación, usan la relación entre los rectángulos de altura y anchura máxima y una RNMPD para clasificar las anticadenas máximas en la estructura reticular. Presentan una comparación con algunos algoritmos conocidos para la construcción de retículas de conceptos [33].

En el 2016, Elizabeth Guevara bajo la supervisión de Humberto Sosa escribe la tesis “Método para el entrenamiento de neuronas morfológicas con procesamiento dendral”, cuyo objetivo es definir una nueva forma de entrenar redes neuronales para mejorar su desempeño y de esta manera, resolver problemas reales de reconocimiento de patrones. Para mostrar la eficiencia del algoritmo se realizaron una serie de experimentos de clasificación de patrones, tanto en datos obtenidos de manera sintetica como en bases de datos y aplicaciones reales. Entre los datos sintéticos se encuentran el problema del espiral y los datos de Ripley, con lo que se realizaron experimentos para comparar el desempeño con el algoritmo de entrenamiento de eliminación de Ritter [34].

En el año 2014, en la tesis “Análisis comparativo de técnicas de reconocimiento de rostros basado en modelos y en imagen usando un módulo de Inteligencia Artificial en MATLAB” de M. Sarango y M.Mainato, se planteó que al analizar e investigar las técnicas de reconocimientos de rostros se pueden profundizar y ampliar más los conocimientos con la finalidad de elegir cuál de ellas es la más adecuada para realizar el prototipo deseado. Es por ello que su objetivo fue el de realizar un estudio comparativo de las diferentes técnicas de reconocimiento de rostros basado en modelos y en imagen usando MATLAB. Para cumplir dicho objetivo fue necesario MATLAB y MySQL y utilizar el algoritmo de Grafos Elásticos de Racimo, gracias a esto se desarrollaron dos prototipos de reconocimiento facial utilizando el lenguaje de programación MATLAB con su Toolboxes, las cuales hacen la detección de la cara, extracción de las características del rostro y finalmente hace la verificación y reconocimiento de la persona [35].

En el año 2015, se publicó la tesis de T. Guerrero, quien para obtener el grado de Maestría en Ciencias e ingeniería de cómputo presentó la implementación de una red neuronal morfológica con procesamiento dendral en un FPGA, donde el objetivo es Implementar una RNMD en un dispositivo FPGA para resolver problemas de clasificación con p clases para una y dos dimensiones ya que el algoritmo que se propone crece exponencialmente a medida que el número de dimensiones incrementa; por lo tanto el tiempo de cálculo de los hiper-cubos deja de ser practico. Para que esto fuera posible fue necesario apoyarse de herramientas computacionales como MATLAB y el lenguaje VHDL. El autor pudo concluir que es posible implementar en una arquitectura tipo FPGA una RNMD y su algoritmo de entrenamiento, compuesta de una sola neurona y K dendritas para el caso de p clases de 1 y 2 dimensiones [36].

1.6.1 Análisis del estado de arte

El advenimiento de Sistemas Robóticos complejos, en diferentes aplicaciones como: manufactura, ciencias de la salud y aeroespaciales, ha desarrollado una demanda para utilizar sistemas de Inteligencia Artificial con mejores características y desempeño debido a que se trata de una disciplina en constante evolución, pero pueden concretarse en grandes áreas: sistemas de procesamiento del lenguaje natural, sistemas de reconocimiento de la Visión, Robótica, sistemas basados en el conocimiento, sistemas expertos y Redes Neuronales, siendo esta última, una de las más utilizadas para reconocimiento de imágenes, ya que tratan de resolver de forma eficiente problemas en los cuales la información es difusa, incierta, contradictoria o errónea. Por este motivo, cada vez son más las personas que han optado por usar esta metodología en sus proyectos, un ejemplo de ello es implementación de una RNMD en un dispositivo FPGA para resolver problemas de clasificación con n clases para una y dos dimensiones. Las investigaciones encontradas en la literatura, se apoyan de diversas herramientas computacionales como matlab, visual studio, mysql y la librería OpenCV para llevar a cabo los objetivos de los diferentes proyectos. Cabe señalar, que para poder hacer uso de esas herramientas computacionales, es necesario tener conocimiento de diferentes lenguajes de programación como C++, C#, o java. (Véase Tabla 1)

Tabla 1 Tabla comparativa de trabajos relacionados con el proyecto

Autor y año	Problemática	Objetivos	Nombre del método, metodología o algoritmos	Herramienta utilizada o requerimientos	Resultados
P. García 2013	Desarrollar aplicaciones para teléfonos móviles que sean capaces de identificar imágenes de forma rápida y sin consumo excesivo de recursos.	Desarrollar un sistema de reconocimiento de imágenes para dispositivos móviles, capaz de funcionar en modo local.	<ul style="list-style-type: none"> • Análisis de Componentes Principales Redes Neuronales backpropagati on 	OpenCV Visual Studio con C++ Teléfono Móvil Servidor IIS	El sistema es capaz de identificar las imágenes que se capturan en buenas condiciones. Se consiguió demostrar que la infraestructura creada era adecuada para el propósito de la investigación.
L. Blázquez 2013	Realizar un sistema que comprueba la validez de sistemas comerciales basados en el marcado de puntos característicos de la cara, y que en caso de fallo, los corrija.	Segmentar la cara y realizar el análisis exhaustivo de cada uno de los rasgos faciales extraídos.	<ul style="list-style-type: none"> • Grafos elásticos (Elastic Bunch Graph Matching, EBGM) • Modelo de apariencia activa (AAM) 	FaceSDK	Incorporar varios vectores de características con diferentes poses para crear los modelos de entrenamiento, es una forma de superar la falta de robustez frente a la variabilidad de pose entre los datos de entrenamiento y de test.
M. Peña, R. Osorio 2013	Mal desempeño de tareas de ensamble con robots industriales que trabajan en ambientes no estructurados, utilizando percepción visual y nuevas técnicas de aprendizaje.	Mostrar un método que considere el diseño de un sistema de visión robusto, en aplicaciones de tiempo real en tareas de manufactura y ensamble con sistemas robotizados.	<ul style="list-style-type: none"> • Paradigma señal-símbolo 	red neuronal artificial del tipo FuzzyARTM AP	Se mostró la factibilidad del uso de esta metodología para aplicaciones de manufactura inteligente realizando tareas de ensamble con robots en tiempo real
M. Sarango M. Mainato 2014	Profundizar y ampliar los conocimientos sobre técnicas de reconocimientos de rostros para elegir la más adecuada y realizar el prototipo deseado.	Realizar el estudio comparativo de las técnicas de reconocimiento de rostros usando un módulo de Inteligencia Artificial en MATLAB.	<ul style="list-style-type: none"> • Algoritmo Elastic Bunch. Graph (Grafos elásticos de racimo). 	Matlab MySQL Windows Cámara IP	Se desarrollaron dos prototipos de reconocimiento facial las cuales hacen extracción de las características del rostro y la verificación y reconocimiento de la persona.
T. Guerrero 2015	El algoritmo crece a medida que el número de dimensiones incrementa; por lo tanto el tiempo de cálculo de los hiper-cubos deja de ser practico	Implementar una RNMD en un dispositivo FPGA para resolver problemas de clasificación con p clases para una y dos dimensiones	<ul style="list-style-type: none"> • Red Neuronal con procesamiento dendral 	MATLAB Lenguaje VHDI	Implementar una arquitectura FPGA en una RNMD y su algoritmo de entrenamiento, compuesta de una sola neurona y K dendritas para el caso de clases de 1 y 2 dimensiones.

1.7 Estructura de la tesis

Este documento consta de 5 capítulos:

- El *primer capítulo* inicia dando una descripción sobre los antecedentes de las redes neuronales, la problemática a resolver, el objetivo, y la justificación, incluyendo en este último los alcances y limitaciones. El resto de este documento está organizado de la siguiente manera:
- En el *segundo capítulo* se describen los fundamentos teóricos de las herramientas utilizadas para la elaboración del proyecto.
- En el *tercer capítulo* se presenta metodología utilizada para llevar a cabo la resolución del problema planteado.
- En el *cuarto capítulo*, se muestran los resultados de la red y se comparan con el de otras redes neuronales para determinar su eficiencia
- En el *último capítulo* se detallan las conclusiones a las que se llegó con la elaboración de la tesis, y se recomiendan trabajos futuros. Para finalizar, se enlistan las referencias bibliográficas utilizadas para la elaboración del proyecto.

1.8 Conclusiones del capítulo

Se dio a conocer el objetivo principal del presente trabajo, se planteó el problema y se describieron los alcances y limitaciones del mismo.

En el subtema “estado del arte” se enlistaron varios trabajos de diferentes investigadores relacionados con el proyecto, así como la metodología y las herramientas que utilizaron para la realización de su investigación.

CAPÍTULO 2 MARCO CONCEPTUAL

En el capítulo que se presenta a continuación se presentan los conceptos fundamentales para facilitar la comprensión de los capítulos posteriores del trabajo que se está presentando.

Se realiza una descripción detallada de cada tema, se comienza con temas generales, como es el reconocimiento facial y las redes neuronales y se continúa describiendo temas específicos, como la definición de una Red Neuronal Morfológica con Procesamiento Dendral, y el reconocimiento facial en entornos no controlados, así como la explicación de lo que es el síndrome pediátrico dismorfogénico facial. Definiciones detalladas con el fin de entender la información comprendida en capítulos posteriores.

El avance tecnológico que se ha producido en las últimas décadas en el campo de la ingeniería informática, ha creado multitud de nuevas ramas científicas y campos de investigación. La tecnología, y en especial los ordenadores, están cada vez más ligados e integrados en nuestra vida cotidiana. A continuación se expondrán los temas principales para la mayor comprensión del proyecto [37].

2.1 Reconocimiento de imágenes u objetos en entornos no controlados

Sin duda alguna, uno de los campos más interesantes y revolucionarios es la robótica y su estrecha relación con la inteligencia artificial. Ya no hace falta dominar un lenguaje computacional para interactuar con los sistemas inteligentes. Los sistemas de inteligencia artificial ya son capaces de entender y procesar nuestras órdenes empleando el lenguaje natural [38]. El comienzo de cualquier proceso de reconocimiento, es la cuantificación digital del entorno. El sistema ha de ser capaz de procesar la información obtenida y aplicar los algoritmos adecuados para su procesamiento y correcta interpretación. Ésta etapa resultaría imposible sin un procesamiento previo de la imagen, debido a que los patrones a reconocer pasan a ser infinitos [39]. El sistema debe de ser capaz de identificar al objeto independientemente de su iluminación, color o posición, y en el caso del reconocimiento facial, también debe de trabajar aun cuando el rostro presente alteraciones (es decir, gestos o malformaciones) dentro de la imagen, y por lo tanto ha de conocer a todas las infinitas posibles variaciones que el objeto puede presentar.

Cuando se adquiere una imagen mediante cualquier sistema de captura, por lo general ésta no se utiliza directamente por el sistema de visión, ya que la aparición de variaciones en intensidad debidas al ruido, por deficiencias en la iluminación o la obtención de imágenes de bajo contraste hace necesario un preprocesamiento de la imagen con el objetivo fundamental de corregir estos problemas, además de aplicar aquellas transformaciones a la imagen que acentúen las características que se deseen extraer de las mismas, de manera que se facilite las operaciones de las etapas posteriores [40].

2.2 Iluminación y oclusioniones

La iluminación es el aspecto más decisivo de cualquier aplicación de visión artificial, si el objeto tiene una buena iluminación se pueden lograr muy buenos resultados en nuestro sistema de reconocimiento de objetos. Muchas aplicaciones buenas han fallado por la falta de una iluminación apropiada [41]. En un sistema de visión artificial, la mejor imagen es aquella que tiene mayor contraste, donde las áreas de interés se destacan del fondo que no tiene mayor importancia.

La luz es reflejada de dos maneras llamadas reflexión especular y reflexión difusa. En la reflexión especular, cada rayo incidente se refleja en una única dirección como en el caso del algunos metales o el espejo, que pueden saturar el sensor de la cámara, en este caso lo mejor es utilizar alguna técnica de iluminación especial. Las reflexiones difusas son tenues pero estables, la intensidad de reflexión puede ser de 10 a 1000 veces menor que la fuente de luz [42].

Los cambios provocados por la iluminación son normalmente más grandes que las diferencias entre personas, causando a los sistemas basados en comparación a equivocarse al clasificar las imágenes de entrada. Se han propuesto algunas soluciones basadas en el conocimiento, en particular teniendo en cuenta que todas las caras pertenecen a una misma clase. Estas técnicas están divididas en 4 tipos [43]:

- *Métodos heurísticos*: cuando utilizamos los subespacios de eigenfaces, descartando las componentes principales.
- *Métodos de comparación de imágenes*: se utilizan representaciones apropiadas de la imagen y medidas de distancia.
- *Métodos basados en la clase*: utilizan múltiples imágenes de la misma cara en una pose fija pero bajo diferentes condiciones lumínicas.
- *Métodos basados en el modelo*: utilizan modelos 3D.

A la hora de reconocer un objeto en una imagen nos encontraremos con varios problemas que evitan que podamos determinar de qué modelo-objeto se trata. Cuando se capturan imágenes de una escena real del mundo, en la que interactúan distintos objetos, y además cuyas condiciones de luz puntos de vista, posiciones y orientación de los objetos varían

con el tiempo se hace muy costoso identificar los objetos presentes en la imagen [44]. El principal problema que impide esta identificación de los objetos presentes en la imagen viene determinado por la presencia de lo que se conoce como oclusiones, datos espurios y ruido.

Hay distintas maneras de clasificar el tipo de oclusión producida, así, en primer lugar una posible clasificación que se propone para las oclusiones podría realizarse en función del tipo de causa o factor que lo provoca. Se pueden distinguir los siguientes tipos [45]:

- Oclusiones en las que un objeto tapa una porción del área de otro objeto que se quiere reconocer y que no es del todo visible.
- Oclusiones por opacidad, en la que un objeto por su propia geometría oculta parte del mismo.
- Oclusiones por sombras, en las que el tipo de iluminación produce sombras en la imagen en el propio objeto a reconocer o en el resto de objetos con que interactúa.

El proceso de reconocimiento de un objeto, ya se encuentre ocluido en una escena o no, depende de dos etapas básicas de procesamiento: una primera etapa que agrupa los métodos de extracción de características en la imagen y una segunda etapa conocida como proceso de Matching o correspondencias entre el modelo del objeto y el conjunto de características extraídas del objeto situado en la escena. En definitiva, el objetivo de todo proceso de reconocimiento es clasificar los objetos presentes en la escena de acuerdo a la similitud de sus características con las características del modelo-objeto [46].

2.2.1 Resolución de la imagen

Muchas de las técnicas de reconocimiento facial asumen la disponibilidad de imágenes ideales (buena luz, fondo uniforme y pocas variaciones en la pose). Sin embargo, en aplicaciones sobre escenarios reales la cara se encuentra en un fondo complejo y con variantes en la pose, necesitando de procesamientos previos sobre la imagen que localicen y extraigan la región facial del fondo [14]. Esta tarea es de las más críticas en los sistemas de reconocimiento facial. Hasta mediados de los años 90, los trabajos en detección facial se basaron en imágenes con una cara simple sobre un fondo controlado. Los métodos incluían la utilización de plantillas de la cara, plantillas deformables basadas

en características, color de la piel y redes neuronales. En los últimos años, se buscó trabajar con escenas complejas (fondos desordenados, con condiciones de iluminación impredecibles) surgiendo gran cantidad de métodos [47].

El proceso de adquisición de la imagen desde el objeto hasta su ingreso en el procesador, se logra a través de un dispositivo que debe ser sensible a los cambios de la luz, el cual es una cámara compuesta por elementos fotosensibles que transforman los fotones de la luz en una corriente eléctrica. En la adquisición de la imagen se tienen dos parámetros, uno de ellos es la Resolución. En la actualidad existen dispositivos de captura de imágenes que poseen una resolución de alta calidad, con cámaras digitales de poco más de 50 Mp [48]. Sin embargo, es necesario tener conocimiento de que resolución es la adecuada para trabajar en el proceso que se va a realizar, ya que una cámara de baja calidad puede distorsionar la imagen y suprimir objetos.

2.2.2 Formatos de imágenes

El almacenamiento de imágenes en forma digital se hace en diversos formatos, de acuerdo al uso que se le va a dar. Es decir, la calidad de la imagen no puede ser la misma para un diseñador gráfico que desea hacer una presentación con animaciones y para un desarrollador de software que desea trabajar con imágenes fijas para un sistemas de reconocimiento facial; es por esta incompatibilidad de formatos que en ocasiones, los sistemas de reconocimiento presentan problemas [49]. La mayoría de las veces para almacenar fotografías se puede leer con una buena calidad se utilizan los formatos *.bmp* y *.tiff*, pero su tamaño es 10 veces mayor que el de un archivo *.jpg*. A continuación se describen algunos de los formatos que se utilizan con mayor frecuencia y las posibilidades que brinda cada uno [50]:

- *BMP*.- El formato BMP (Bit Map) es el formato de las imágenes en bitmap de Windows. tiene como desventaja la escasa compresión que realiza en los archivos por lo que ocupan mucho espacio. Pero el formato de Mapa de Bits tiene una importante característica a su favor, es que casi todos los usuarios tienen una PC con ambiente gráfico Windows y pueden leerlo desde un accesorio llamado "Paint".
- *TIFF*.- Este tipo de formato corresponde a las siglas Tagged-Image File Format, se utiliza cuando se van a realizar impresiones en papel de la imagen. Es un formato que

admite una compresión muy baja, por lo que la pérdida en la calidad de imagen es prácticamente nula. Se conoce como formato de compresión sin pérdida. Una desventaja es que los archivos .tiff son de gran tamaño.

- *GIF*.-Destacando en sus características la posibilidad de trabajar, con un máximo de 256 colores y con más de una imagen, el GIF es un formato ideal para utilizar en la web en imágenes pequeñas o de pocos colores y no es recomendable para utilizar en impresión, ya que la calidad es limitada.
- *JPEG* o *JPG*.- El formato JPEG (Joint Photographic Experts Group) está diseñado para realizar compresión de imágenes, permitiendo reducir la cantidad de información de las mismas, con una consecuente reducción de peso del archivo final. Es por ello que dicho formato también es de uso común en la web. La resolución de este formato es baja y no es recomendable para la impresión.
- *PCX*.- Este es el formato desarrollado por Zsoft para su programa Paintbrush para PC. En un principio sólo guardaba 16 colores, pero las últimas actualizaciones acomodan el color de 8 y de 16 bits.

2.3 Reconocimiento de rostros

El problema del reconocimiento facial se puede sintetizar como la identificación de un rostro, utilizando únicamente los rasgos faciales, sin utilizar otros elementos (voz, ADN, etc.). Además se han definido otros temas relacionados, como son la expresión facial y la generación de modelos de texturas para su uso en gráficos [51].

En algunos casos las condiciones bajo las que se obtiene la imagen son controladas, por ejemplo fotografías obtenidas por la policía o en un laboratorio. Por lo tanto la localización de la cara en la escena puede ser fácilmente determinada. Sin embargo, en otros casos la localización de la cara en la imagen no es conocida a priori. Por este motivo, el primer paso es determinar si en la escena hay caras, y si este es el caso, localizarla en la imagen [52]. Existen diversos factores, que hacen que este problema sea complejo, un ejemplo de ello es el vello facial (bigote, barba, etc.), maquillaje o alguna dismorfia en el rostro que enmascaran las características faciales.

2.4 Modo identificación

Los sistemas de identificación se emplean para el manejo de información relativa a las personas y a los objetos. Para tal efecto se utilizan formas de registro magnético, óptico, sonoro e impreso [53].

Generalmente, estos sistemas requieren de dos componentes fundamentales: un elemento codificado que contiene la información (es decir, datos procesados siguiendo alguna norma o patrón preestablecido) y un elemento con capacidad de reconocer la información.

Posteriormente, el equipo lector se comunica con una computadora donde se realizan diversos procesos; en primer lugar, los datos son decodificados, esto es, se transforman en información entendible para la computadora. A continuación, la información es verificada, comparada y aceptada para luego realizar alguna decisión lógica [54].

De manera cotidiana los sistemas de identificación de personas pueden ser diversos para el acceso a una cuenta en un banco, a un área restringida, a una computadora, a una línea telefónica, a una empresa, a su casa, a los controles remotos, a las tarjetas de crédito, entre otros [9]. Gracias a que los sistemas modernos son automáticos, los procesos se agilizan, se cometen menos errores y en consecuencia se incrementa la confiabilidad y la eficiencia.

Estos sistemas también son empleados para la identificación de objetos (o en inglés se conocen como ítems -artículos) sobre todo cuando se destinan a usos comerciales. Cuanto mayor es la diversificación, esto es, cuando el número de artículos rebasa la capacidad de clasificación humana, más necesaria es la identificación exacta del objeto [55].

Un sistema de reconocimiento operando en el modo de identificación descubre a un individuo mediante una búsqueda *exhaustiva* en la base de base de datos con los modelos. Esto conduce a una comparación del tipo *uno-a-muchos* para establecer la identidad del individuo. En términos sencillos el sistema responde la pregunta: ¿quién eres tú?

Generalmente es más difícil diseñar un sistema de identificación que uno de verificación. En ambos casos es importante la exactitud de la respuesta. Sin embargo, para un sistema

de identificación la rapidez también es un factor crítico. Un sistema de identificación necesita explorar toda la base de datos donde se almacenan los templates, a diferencia de un sistema verificador [56].

2.5 Modo verificación

Un sistema de reconocimiento operando en el modo de verificación comprueba la identidad de algún individuo comparando la característica sólo con los modelos del individuo. Por ejemplo, si una persona ingresa su nombre de usuario entonces no será necesario revisar toda la base de datos buscando el template que más se asemeje al de él, sino que bastará con comparar la información de entrada sólo con el modelo que está asociado al usuario [57]. Esto conduce a una comparación uno-a-uno para determinar si la identidad reclamada por el individuo es verdadera o no. De manera más sencilla el modo de verificación responde a la pregunta: ¿eres tú quién dices ser?.

2.5.1 Localización de puntos característicos de la cara

En imágenes las características de cada objeto se extraen al aplicar ciertas funciones que permitan la representación y descripción de los objetos de interés de la imagen (patrones). La extracción de características es un paso en el reconocimiento de patrones en el cuál las medidas u observaciones son procesadas para encontrar atributos que puedan ser usados para asignar los objetos a determinada clase [58].

Al tener las zonas u objetos de interés de la imagen, se procede a extraer las características mediante técnicas de extracción de información específicas para el reconocimiento facial, para distinguir entre los rostros de diferentes personas. Entre las técnicas más usadas se encuentran: Principal Component Analysis (PCA), Locality Preserving Projections o Laplacianface (LPP), Linear Discriminant Analysis (LDA), Elastic bunch Graph Matching (EBGM), entre otras [59].

2.6 Métodos para el reconocimiento y clasificación de imágenes u objetos

Como un paso previo al reconocimiento de caras, conviene tener algo de conciencia sobre las técnicas que suelen emplearse para su detección, es decir su localización dentro de

una imagen, ambos casos ponen en práctica algunos métodos y conceptos comunes. Además, la mayoría de las aplicaciones del reconocimiento de caras tienen sentido si esta fase está resuelta adecuadamente.

Estas técnicas de detección se han abordado desde diferentes enfoques [60]:

- Enfoques basados en *rasgos faciales o características locales*, en los que se buscan determinados elementos que componen el rostro, como los ojos, la nariz, la boca.
- Enfoques *holísticos o basados en la imagen*, en este caso los métodos trabajan con la imagen completa o zonas concretas de la misma de la cual se extraen características que puedan representar el objeto buscado.
- Enfoques *híbridos*, estos métodos usan tanto la información local como la global para la detección, basándose en el hecho de que el sistema de percepción humano distingue tanto las características locales como globales del rostro

2.6.1 Reconocimiento estadístico

Los métodos estadísticos clasifican objetos presentes en una imagen reconociéndolos como pertenecientes a una determinada clase de objeto, definido como modelo-objeto, en función de la probabilidad de que tal objeto detectado en la imagen sea identificado como uno u otro modelo-objeto. De modo que el modelo-objeto candidato ideal será aquel que maximiza dicha probabilidad [61]. Al introducir información probabilística, se puede tener en cuenta para el reconocimiento de la incertidumbre en las características extraídas del objeto en la imagen [56]. Es decir, puede darse el caso que algunas de las características extraídas del objeto y que van a ser utilizadas para realizar la correspondencia con las características del modelo objeto, y así determinar la clasificación del objeto representado en la imagen, no son las adecuadas. Esto puede ser debido a que no son las adecuadas porque no pertenecen al objeto sino al fondo o a otro objeto cercano. De modo, que es interesante incorporar distribuciones espaciales a las características que se extraen de la imagen para mejorar el proceso de clasificación [62].

Este método, al utilizar probabilidades de pertenencia determina con mayor exactitud las correspondencias con el modelo y de este modo clasifican mejor los objetos cuando para su clasificación se usan características espurias.

2.6.2 Reconocimiento sintáctico

En su utilización en reconocimiento de formas, la teoría de lenguajes tropezó desde un principio con un problema inherente a este dominio de aplicación: la representación imprecisa de los objetos. Para solventar esta dificultad se hace necesario recurrir a métodos de análisis sintáctico [63].

Entre los métodos estructurales de reconocimiento de formas destacan los métodos englobados en lo que se conoce como reconocimiento sintáctico de formas. Estos métodos intentan aprovechar las técnicas desarrolladas por la teoría de lenguajes formales, las cuales proveen de una representación (las gramáticas) y de un mecanismo de interpretación ("parsing" o análisis sintáctico) para aquellas formas cuyos objetos se pueden describir como cadenas de subobjetos [64].

En pocas palabras el reconocimiento sintáctico es un enfoque que se fundamenta en encontrar las relaciones estructurales que guardan los objetos de estudio, utilizando la teoría de lenguajes formales. El objetivo es construir una gramática que describa la estructura del universo de objetos [65].

2.6.3 Reconocimiento de imágenes utilizando Redes Neuronales

Las redes neuronales son más que otra forma de emular ciertas características propias de los humanos, como la capacidad de memorizar y de asociar hechos [66]. Si se examinan con atención aquellos problemas que no pueden expresarse a través de un algoritmo, se observará que todos ellos tienen una característica en común (la experiencia). El hombre es capaz de resolver estas situaciones acudiendo a la experiencia acumulada [67]. Así, parece claro que una forma de aproximarse al problema consista en la construcción de sistemas que sean capaces de reproducir esta característica humana. En definitiva, las redes neuronales no son más que un modelo artificial y simplificado del cerebro humano, que es el ejemplo más perfecto del que disponemos para un sistema que es capaz de adquirir conocimiento a través de la experiencia [68]. Una red neuronal es "un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona" [69].

2.7 Redes neuronales

Las redes artificiales se basan siempre en funciones lógicas en todos los casos, no admitiéndose por tanto raciocinios que no se encuentren entre sus “bases”, sin embargo, no se sabe muy bien cómo hace las cosas nuestra mente en la mayor parte de las veces, aunque parecen ser el resultado de procesos sumamente complejos en varias partes de nuestro cerebro [37]. Otra gran diferencia es el hecho de que las redes neuronales artificiales se basan por así decirlo en el análisis, algo así como comenzar por una idea fundamental y descomponerla hasta conocer todos sus componentes. Mientras que las redes biológicas basan su funcionamiento en la síntesis pues así es el acercamiento de las redes neuronales: se comienza por un comportamiento inicial y se trata de conformar la inteligencia mediante la unión de estos componentes. A continuación se presentan diferentes tipos de redes neuronales:

1. *Multilayer Perceptron*: Las RNA de tipo Perceptrón Multicapa (PM) se encuentran entre las arquitecturas de red más poderosas y populares. Están formadas por una capa de entrada, un número arbitrario de capas ocultas, y una capa de salida. Cada una de las neuronas ocultas o de salida recibe una entrada de las neuronas de la capa previa (conexiones hacia atrás), pero no existen conexiones laterales entre las neuronas dentro de cada capa [49]. La capa de entrada contiene tantas neuronas como categorías correspondan a las variables independientes que se desean representar. La capa de salida corresponde a la variable respuesta, que en este caso es una variable categórica. Para el entrenamiento de este tipo de red Inicialmente se fijan algunos valores necesarios en el entrenamiento de la red como es el caso del momentum, y la velocidad de aprendizaje [70].

Luego de seleccionados los valores con los que se van a entrenar, y de definir la arquitectura de la red, la velocidad de aprendizaje y el momentum, además de la cantidad de patrones de entrada con que se va a realizar el entrenamiento, la aplicación genera aleatoriamente los pesos sinápticos.

Cada patrón de entrada se hace pasar a través de la estructura activando cada neurona y generando salidas en estas, dichas salidas son multiplicadas por los pesos sinápticos y constituyen la entrada de las neuronas de la capa siguiente, así

sucesivamente hasta llegar a la capa de salida donde el resultado final se compara con el resultado esperado, generando un error el cual es propagado por toda la red (backpropagation) hasta llegar al origen, corrigiendo los valores sinápticos. Así sucede con cada patrón hasta que todos hayan pasado a través de la red, esto constituye una iteración o epoch [71].

El criterio para establecer la condición de parada para el entrenamiento estuvo dado por la cantidad de iteraciones o epochs, o sea, el investigador define la cantidad de iteraciones que considere necesaria para obtener una red neuronal lo suficientemente entrenada para procesar sus datos de manera satisfactoria [72].

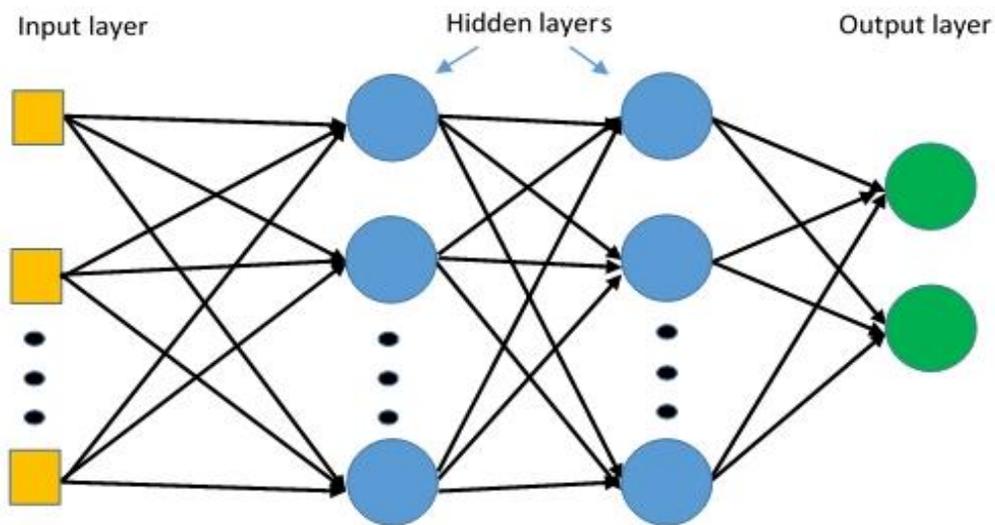


Figura 1 Estructura de Multilayer Perceptron [73]

2. *IBK*: Es un algoritmo que pertenece a la técnica basada en ejemplos que consiste en la clasificación realizada por medio de una función que mide la proximidad o parecido. El BIAS (sesgo) que rige este método es la proximidad, es decir, la generalización se guía por la proximidad de un ejemplo a otros. La técnica basada en ejemplos se suele considerar no adecuada para el tratamiento de atributos no numéricos y valores desconocidos [74]

IBK es el método de los k vecinos más cercanos para regresión, es un método de aproximación sin parámetros, éste, permite resolver problemas de clasificación y regresión. Se basa en la suposición que la clase a la cual corresponde un objeto es la misma a la que pertenecen sus vecinos más cercanos [75]

El KNN es uno de los clasificadores más utilizados por su simplicidad. La principal dificultad de este método consiste en determinar el valor de k , ya que si toma un valor grande se corre el riesgo de hacer la clasificación de acuerdo a la mayoría (y no al parecido), y si el valor es pequeño puede haber imprecisión en la clasificación a causa de los pocos datos seleccionados como instancias de comparación [76].

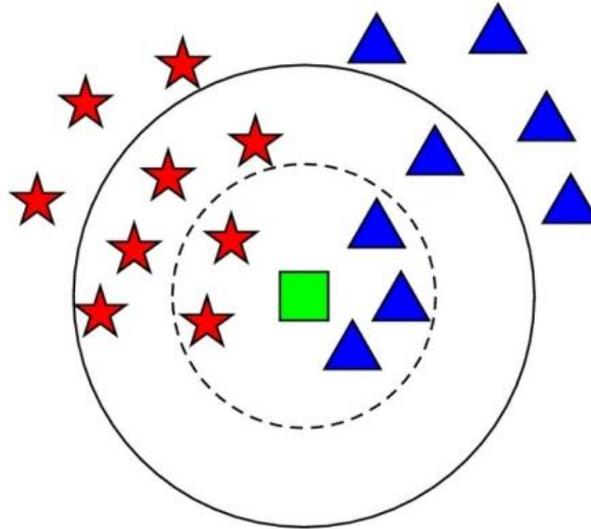


Figura 2 Ejemplo Algoritmo IBK [77]

3. *SOM (Self Organizing Map)*: también conocida como los mapas auto-organizados de Kohonen se creó con el fin de simular la abstracción sensorial de la información del entorno en los seres humanos de manera bidimensional. Kohonen (1982) propuso el modelo neuronal de la red SOM con el objetivo de demostrar que a partir de estímulos externos o datos de entrada de espacios multidimensionales, la estructura propia de la red artificial puede describir y proyectar la información abstraída en los estímulos, organizando datos de salida en un mapa bidimensional.

Un modelo SOM está compuesto por dos capas de neuronas. La capa de entrada (formada por N neuronas, una por cada variable de entrada) se encarga de recibir y transmitir a la capa de salida la información procedente del exterior. La capa de salida (formada por M neuronas) es encargada de procesar la información y formar el mapa de rasgos de Palmer, la Figura 3 representa de manera intuitiva la estructura del modelo de la Red (SOM) [78].

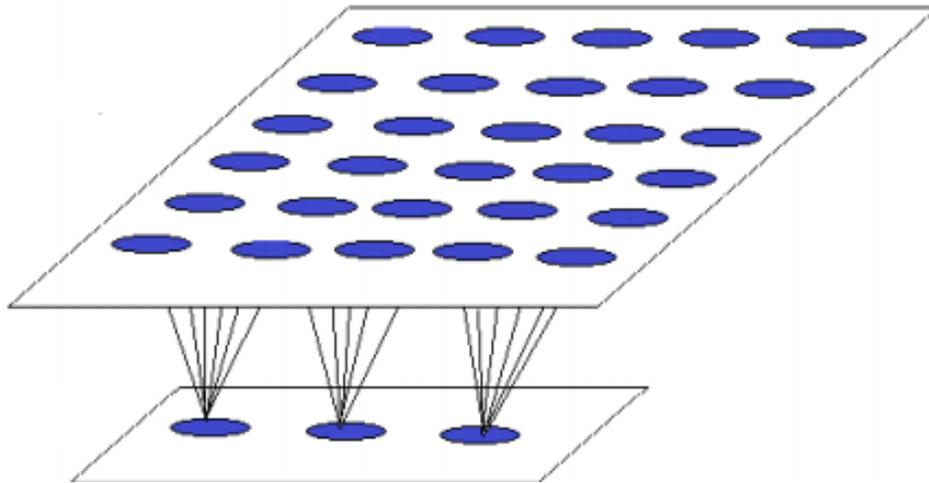


Figura 3 Estructura de la red SOM [79]

2.7.1 Biológicas

El cerebro puede considerarse un sistema altamente complejo. Su unidad básica, la neurona, está masivamente distribuida con conexiones entre ellas (se calcula que hay aproximadamente 10 billones de neuronas en la corteza cerebral y 60 trillones de conexiones neuronales [80]). Modelo Biológico (Ver Figura 4):

- Ramas de extensión o dendritas: Reciben estímulos de entrada.
- Cuerpo de la Neurona: Procesa estímulos de entrada.
- Axón: Emite estímulos de salida a las dendritas de otras neuronas.

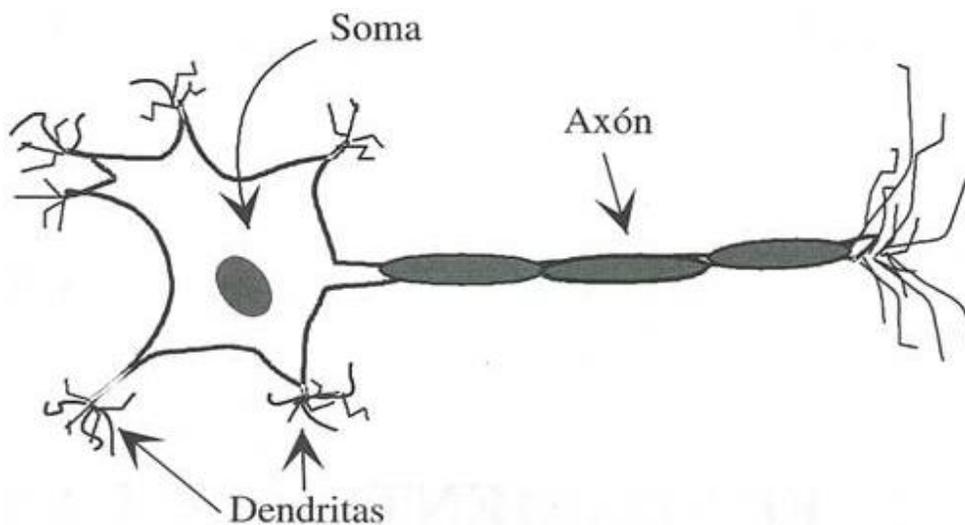


Figura 4 Neurona Biológica [81]

La función principal de las neuronas es la transmisión de los impulsos nerviosos. Estos viajan por toda la neurona comenzando por las dendritas hasta llegar a las terminaciones del axón, donde pasan a otra neurona por medio de la conexión sináptica [82]. El objetivo principal de las redes neuronales de tipo biológico es desarrollar un elemento sintético para verificar las hipótesis que conciernen a los sistemas biológicos [83].

El sistema de neuronas biológico está compuesto por neuronas de entrada (sensores) conectados a una compleja red de neuronas “calculadoras” (neuronas ocultas), las cuales, a su vez, están conectadas a las neuronas de salidas que controlan [84].

2.7.2 Artificiales

Las redes neuronales (ANN) son modelos computacionales diseñados para simular el funcionamiento del cerebro y, en particular, la forma como éste procesa información. En el contexto de análisis de series de tiempo, se clasifican como modelos no lineales entrenados para realizar conexiones entre los valores pasados y presentes de una serie de tiempo y extraer estructuras y relaciones escondidas que gobiernan el sistema de información [85]. El atractivo de este enfoque, inspirado en la neurología, es su habilidad para aprender, es decir, para identificar dependencias con base en una muestra finita, de manera que el conocimiento adquirido pueda ser generalizado a muestras no observadas (Herbrich et.al, 1999). Si bien, como señalan Kuan y White (1994), las redes neuronales y sus algoritmos de aprendizaje asociados están todavía lejos de ofrecer una descripción acertada de cómo funciona el cerebro, éstas se han constituido en un marco de modelación muy poderoso e interesante cuyo potencial ha sido comprobado en diversas aplicaciones en todas las ciencias. Para Moshiri y Cameron (1998), los investigadores son atraídos hacia ese enfoque porque las redes neuronales no están sujetas a supuestos restrictivos como la linealidad, que suele ser necesaria para la aplicación de los modelos matemáticos tradicionales [86].

A grandes rasgos las RNA son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico.

2.7.2.1 Lattice

El cerebro humano es la conformación más compleja conocida de la estructura de la lattice (exceptuando la estructura fundamental de la lattice misma). Cada una de las doce mil millones de neuronas del cerebro humano junto con todas sus conexiones anatómicas son otras tantas alteraciones de la estructura fundamental de la lattice. Cada vez que una neurona se activa y su membrana celular cambia su potencial de reposo produciendo cambios eléctricos de superficie, la lattice cambia su conformación. El conjunto de las modificaciones de la estructura de la lattice que resultan de toda la actividad del cerebro crea una alteración colosalmente compleja de la lattice [87].

El concepto de lattice se introdujo para generalizar y unificar ciertas relaciones que existen entre subconjuntos de ciertas estructuras como grupos, campos, espacios topológicos, etc.

El desarrollo de la teoría de lattice comenzó alrededor de 1930 y fue influenciado por las obras de Birkhoff [66]. La teoría general de conjuntos parcialmente ordenados se basa en una única relación indefinida. La teoría de lattice también se basa indirectamente en esta relación, pero directamente en dos operaciones binarias que son análogas en muchos aspectos a la adición ordinaria y la multiplicación. Es esta analogía que hace que la teoría del lattice sea una rama del álgebra [88].

Una lattice es un conjunto parcialmente ordenado de L , cuyos dos elementos x, y tienen un lub o unión, denotado por $x \vee y$, y un glb o meet, denotado por $x \wedge y$. La lattice simbólicamente se escribe de la siguiente manera (L, \vee, \wedge) .

La arquitectura con estructuras de Lattice, se definen como la clase de algoritmos que construyen cálculos utilizando los operadores de red latente inferior y superior, o el uso de la teoría de la red para producir generalizaciones o fusiones de enfoques. En las últimas décadas se han producido una serie de algoritmos para el procesamiento de datos, clasificación y filtrado de señales [89].

Una lattice es un conjunto parcialmente ordenado (poset) cualquiera de estos elementos tienen un superior y un inferior. Las operaciones inferiores y superiores son relaciones binarias que corresponden a cualquier par de objetos en el conjunto.

Un sublattice de una red L es un subconjunto X de L tal que para cada par $x, y \in X$, tenemos que $x \wedge y \in X$ y $x \vee y \in X$.

Se dice que una lattice L está completa si y sólo si para cada uno de sus subconjuntos X , $\inf X$ y $\sup X$ existen. Definimos los símbolos $\bigvee X = \inf X$ y $\bigwedge X = \sup X$. (Ver Figura 5)

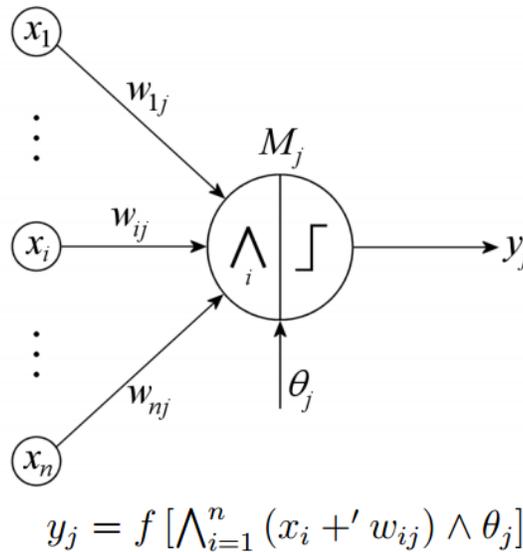


Figura 5 Modelo de Red Neuronal basado en Lattice [90]

- Características

Muchos algoritmos computacionales en los diversos campos de la ciencia, incluida la Inteligencia computacional, se definen como la estructura algebraica dada por el anillo de los números reales, la adición y la multiplicación $(\mathbb{R}, +, \times)$. Sin embargo, existe una línea paralela de trabajos basados en operadores algebraicos, como $(\mathbb{R}, \vee, +)$ o su dual $(\mathbb{R}, \wedge, +)$, donde el papel de la adición es tomada por la operación reticular inferior o superior y la función de multiplicación es tomada por la adición [74].

A un nivel muy abstracto, podemos distinguir el tipo de procesos realizados en aplicaciones computacionales y métodos de inteligencia en tres grupos básicos:

Filtrado: mapas de objetos (es decir, señales) en un espacio de alta dimensión son representados por

$$F: \mathbb{R}^N \rightarrow \mathbb{R}^N.$$

Ecuación (1)

Reducción de la dimensión: mapas de objetos en un espacio de alta dimensión, se reducen a espacios de dimensión inferior por medio de la Ecuación (22)

$$F: \mathbb{R}^N \rightarrow \mathbb{R}^d \text{ con } d \ll N$$

Ecuación (2)

Clasificación: Cartografía de objetos en un espacio (de alta dimensión) en categorías, donde la construcción se puede hacer de una manera supervisada o no supervisada (clustering), representada por:

$$F: \mathbb{R}^N \rightarrow \Omega \text{ con } \Omega = \{\omega_1, \dots, \omega_c\}$$

Ecuación (3)

El álgebra de imágenes es otro intento temprano para definir los métodos de computación de lattice dedicados al tratamiento de imágenes. Los trabajos recientes identifican la teoría de lattice y la teoría algebraica estructuras basadas en operadores de celosía como concepto central para toda una familia de métodos aplicaciones. La arquitectura Fuzzy-ART es uno de los primeros conceptos de la computación lattice en el aprendizaje [91].

2.7.2.2 RNMPD

Las investigaciones sobre el álgebra de imagen fueron el prelude de la propuesta de redes neuronales morfológicas, en forma de morfológicas Perceptron y de las memorias asociativas. Fueron propuestas para el almacenamiento de patrones binarios y grises, con el objetivo de recuperar la imagen original de copias ruidosas, que es un proceso de la restauración de la imagen. También en escala de grises morfológica las memorias asociativas se utilizan para pre-procesar los datos antes de la clasificación un enfoque de vecinos más cercanos [101].

De acuerdo a lo antes mencionado existe una nueva clase de redes neuronales artificiales llamadas redes neuronales morfológicas con procesamiento dendral (RNMPD). Dichas redes utilizan máximos o mínimos y de sumas para llevar a cabo sus operaciones, a diferencia de la mayoría de las redes neuronales, las cuales basan su funcionamiento en sumas de productos [101].

Con el planteamiento de este tipo de esquema y con la incorporación de nuevas ideas neuronales con procesamiento en sus dendritas, las redes neuronales morfológicas han podido igualar y en ocasiones superar el rendimiento de otro tipo de redes neuronales.

Los modelos de redes neuronales artificiales son especificados por la red Topología, las características del nodo y la formación o aprendizaje reglas. El sistema algebraico subyacente utilizado en estos modelos es el conjunto de números reales \mathbb{R} junto con las operaciones de adición y multiplicación y las leyes que rigen estas operaciones. Este sistema algebraico, conocido como un anillo, es comúnmente denotado por $(\mathbb{R}, +, *)$.

Los cálculos básicos que ocurren en la red morfológica propuesta se basan en la estructura de la red algebraica $(\mathbb{R} \pm \infty, \vee, \wedge, +, +')$. El álgebra de matrices sobre $\mathbb{R} \pm \infty$ que ha encontrado aplicaciones extendidas en las ciencias de la ingeniería proporciona una manera elegante de expresar el efecto de entrada total en una capa de la red neuronal morfológica [76].

Debido a las limitaciones de espacio, una discusión de este álgebra no puede darse en este artículo. El conjunto $\mathbb{R} \pm \infty$ contiene los números reales junto con los límites superior e inferior ∞ y $-\infty$. Este conjunto forma un grupo ordenado reticulado. Los símbolos \vee y \wedge indican las operaciones binarias de máximo y mínimo, respectivamente. Las operaciones \vee y \wedge actúan sobre $\mathbb{R} \pm \infty$ de la manera usual. Las operaciones $+$ y $+'$ sólo difieren entre sí en el siguiente aspecto:

$$\infty + (-\infty) = (-\infty) + \infty = \infty \quad \text{Ecuación (4)}$$

$$\infty +'(-\infty) = (-\infty) +' \infty = -\infty \quad \text{Ecuación (5)}$$

De lo contrario estas operaciones se comportan como el lector esperaría. Por ejemplo, $\infty + x = \infty$ y $-\infty + x = -\infty$ para cada $x \in \mathbb{R} \subseteq \mathbb{R} \pm \infty$. Por lo tanto, no es necesario distinguir entre los operadores binarios $+$ y $+'$ si uno de los operandos se sabe que es real como es el caso de las entradas de las redes neuronales morfológicas [83].

Las redes neuronales morfológicas utilizan operaciones de tipo lattice, \vee (máximo) o \wedge (mínimo), y $+$ para los semi-anillos $(\mathbb{R}^{\infty, \vee}, +)$ o $(\mathbb{R}^{\infty, \wedge}, +)$ donde $\mathbb{R}^{-\infty} = \cup \{-\infty\}$ y $\mathbb{R}^{\infty} = \cup \{\infty\}$. El cálculo de la neurona en una red neuronal morfológica para una entrada $x = (x_1, x_2, \dots, x_n)$ está dado por las siguientes ecuaciones:

$$t_j = a_j \vee_{i=1}^n b_{ij}(x_i + w_{ij})$$

Ecuación (6)

ó

$$t_j = a_j \wedge_{i=1}^n b_{ij}(x_i + w_{ij})$$

Ecuación (7)

en donde $b_{ij} = \pm 1$ denota si la i -ésima neurona ocasiona excitación o inhibición en la j -ésima neurona, $a_j = \pm 1$ denota la respuesta a la salida (excitación o inhibición) de la j -ésima neurona a las neuronas con las cuales sus axones tienen contacto y w_{ij} denota la fuerza sináptica entre la i -ésima neurona y la j -ésima neurona. Los parámetros b_{ij} y a_i toman el valor de $+1$ ó -1 dependiendo de si la i -ésima neurona de entrada causa excitación o inhibición a la j -ésima neurona.

El cálculo realizado por la k -ésima dendrita puede ser expresado mediante la siguiente formula:

$$D_j(x) = a_k \wedge_{i \in I} \wedge_{l \in L} (-1)^{1-l} (x_i + w_{ij}^l)$$

Ecuación (8)

En donde $x = (x_1, x_2, \dots, x_n) \in \mathbb{R}^n$ corresponde a las neuronas de entrada, $I \subseteq \{1, \dots, n\}$ denota al conjunto de todas las neuronas de entrada N_i , con fibras terminales de sinapsis en la dendrita k th de una neurona morfológica N , $L \subseteq \{0, 1\}$ corresponde a el conjunto de las fibras terminales de la i -ésima neurona que hace sinapsis con la k -ésima dendrita de N , y $a_k \in \{-1, 1\}$ denota la respuesta de excitación o inhibición de la k -ésima dendrita.

Claramente, $I \neq \emptyset$ y $L \neq \emptyset$ ya que hay al menos una fibra axonal proveniente de al menos una de las neuronas de entrada con la sinapsis de la dendrita k [84]. La función de activación

usada en las redes neuronales morfológicas es una función de límite duro, la cual asigna 1 si la entrada es mayor o igual a 0 y asigna 0 si la entrada es menor que 0.

Las redes neuronales morfológicas, difieren de los modelos clásicos en la manera en que modelan la interacción entre las señales de entrada y los diferentes parámetros de la neurona. En particular, las señales interactúan con los pesos sinápticos de manera aditiva y no multiplicativa; así pues, el procesamiento de la información tanto en las dendritas como en el cuerpo celular se realiza haciendo uso de operadores morfológicos (máximo y mínimo) y no sumas como en el caso clásico [102].

Una RNMPD es algebraicamente distinta a las clásicas redes neuronales artificiales así como también sus aplicaciones. La principal diferencia entre las redes clásicas y las morfológicas, se da en la manera en la que cada nodo combina algebraicamente la información numérica. Cada nodo en una red neuronal clásica combina la información mediante la multiplicación de los valores de la salida con su correspondiente peso y posteriormente la suma de los mismos, mientras que en una RNMPD, la combinación de las operaciones consiste en la suma de los valores con sus correspondientes pesos, para así posteriormente formar el valor máximo.

Un Perceptrón morfológico de una sola capa con estructuras dendríticas o, un perceptrón morfológico de una sola capa (SLMP), consiste en n neuronas de entrada y m neuronas de salida, denotadas respectivamente por N_i , con $i = 1, \dots, N$, y M_j , con $j = 1, \dots, M$. Los axones de las neuronas de entrada se dividen en ramas cuyas fibras terminales entran en contacto con las dendritas de las neuronas de salida.

Al igual que con las estructuras neurales biológicas y en contraste con el modelo clásico de un perceptrón de una sola capa, una neurona de salida puede tener múltiples sitios sinápticos de contacto de la misma neurona de entrada. El valor de una neurona de entrada N_i se propaga a través de su árbol axonal a las ramas terminales que hacen contacto en los sitios sinápticos de las dendritas de las neuronas de salida.

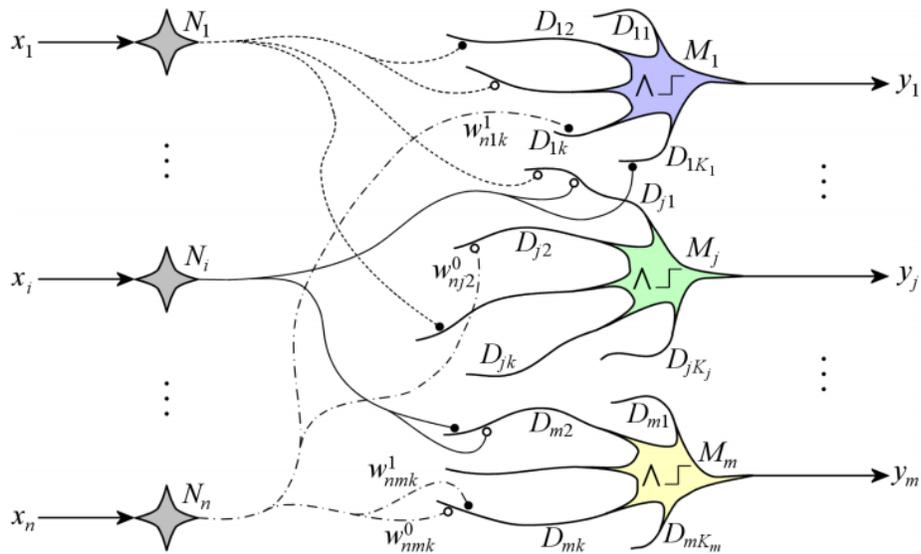


Figura 6 Perceptrón morfológico de una sola capa con estructuras dendríticas [103].

Las redes neuronales morfológicas con procesamiento en dendral son una alternativa a las redes neuronales clásicas (Ver Figura 6). Hasta el momento este tipo de redes neuronales se han implementado (de acuerdo a la investigación realizada) en máquinas secuenciales utilizando diversos lenguajes de programación tales como: MATLAB, C, C#, entre otros.

2.8 Síndrome Pediátrico Dismorfogénico facial

2.8.1 Distrofia Acro-Osteólitica

Es una afección de naturaleza hereditaria según un modo de transmisión autosómica recesivo caracterizada por enanismo micromélico, disostosis cleidocraneana y osteopetrosis predominante en cráneo y manos. Constituye una de las tantas formas de enanismo micromélico que es necesario diferenciar de la acondroplasia cuyas características han sido bien establecidas. La entidad fue descrita en 1962, plenamente identificada y definida en 1965 y muy probablemente la enfermedad sufrida por el pintor Henri de Toulouse-Lautrec [38].

Hasta hace algún tiempo la picnodisostosis fue confundida con la osteopetrosis de Albers-Schönberg, la disostosis cleidocraneana y la displasia diafisaria (Camurati-Engelmann). La descripción original de Maroteaux y Lamy se basa sobre 26 casos encontrados durante un periodo largo por lo que es de suponer que es una afección rara. Puede encontrarse en

los dos sexos con igual frecuencia [3]. El cuadro clínico es bastante simple pero igualmente sin especificidad: el enanismo es constante pero variable según el caso y la estatura puede estar comprendida entre 1,35 y 1,50 m. El cráneo es grande, el frontal y el occipital prominentes, la fontanela anterior francamente abierta, el maxilar inferior hipoplásico [92]. El tórax puede ser un poco estrecho y moderadamente deprimido por debajo de la región mamaria; las clavículas son delgadas y la extremidad externa eventualmente falta. Manos y pies son cortos lo mismo que los huesos tubulares; las uñas son a veces anormales con múltiples fisuras y quebradizas.

Los exámenes de laboratorio son normales y no ha podido observarse ninguna anomalía del metabolismo fosfo-cálcico.

El curso de la picnodisostosis es relativamente benigno: no hay anemia ni compromiso de pares craneanos y la tendencia a las fracturas es considerablemente menos marcada que en la osteopetrosis. En este caso tampoco hay tratamiento específico.

2.8.2 Síndrome Ectrodactilia-Displasia, Ectodérmica-Fisura palatina

Este síndrome se caracteriza por la presencia de la triada Ectrodactilia-Displasia Ectodérmica-Hendidura (EEC). Esta asociación muchas veces es confundida con otro tipo de identidades quedando así erróneamente diagnosticado el paciente, por lo cual se plantean variados diagnósticos diferenciales del mismo [44]. El siguiente trabajo tiene como objetivo la presentación de un caso clínico de un paciente masculino de 5 años de edad con el diagnóstico presuntivo de Displasia Condroectodérmica y el cual cursaba con hendidura labio-palatina completa bilateral asociada a discromía del cabello, ectrodactilia de manos y pies, polidactilia post-axial, trastornos dentarios y obstrucción de ambos ductos lagrimales. Para tal efecto, se realizó un estudio genético, examen clínico, radiografía panorámica y de tórax, evaluación oftalmológica y neurológica [45]. De estos exámenes se pudo concluir que en base a las características genéticas y clínicas representaba un caso de Síndrome EEC. Estos resultados sugieren que el diagnóstico de este tipo de identidades clínico-patológicas debe realizarse conjuntamente por un grupo de especialistas médico-odontológicos, para de esta forma establecer un plan de tratamiento adecuado para el paciente. Finalmente se describe en detalle el diagnóstico y plan de tratamiento dental instaurado en el paciente.

2.9 Conclusiones del capítulo

En este capítulo se describió de manera detallada que es el reconocimiento facial y como se lleva a cabo en ambientes controlados y no controlados (es decir, con problemas de iluminación, oclusión o dismorfias faciales en algunas personas), se describió también que es una red neuronal, tanto biológica como artificial. Se enlistan algunos de los métodos clasificadores más utilizados en el área de estudio.

Se describió también que es el Síndrome Pediátrico Dismorfogénico facial, así como algunas enfermedades relacionadas con el mismo.

CAPÍTULO 3 RNA'S PARA MEDIR EL NIVEL DE DISMORFIA FACIAL EN LABIO LEPORINO

Este capítulo representa gran importancia para el presente trabajo, puesto que expone la metodología utilizada para el entrenamiento de una RNMPD capaz de medir el nivel de asimetría en personas con dismorfia facial en labio leporino.

Para conocer la eficiencia de la red se presenta el algoritmo de entrenamiento que se utilizó y un ejemplo del mismo.

En el capítulo anterior se mostró la estructura de una RNMPD y sus características. Ahora abordamos la tarea de lograr que la red “aprenda” a resolver un problema. El entrenamiento de las redes neuronales es un caso de aprendizaje supervisado, se dice que es así cuando el objetivo es aprender una función a partir de ejemplos de sus entradas y salidas. Para llevar a cabo esto, se realiza la descripción detallada del algoritmo de entrenamiento y se mencionan sus características principales. Una desventaja importante del método formulado inicialmente es que el tiempo de entrenamiento crece exponencialmente al aumentar el número de rasgos. Sin embargo, en la presente investigación se encontraron modificaciones que permitieron eliminar esta característica para ciertos problemas, de tal manera que se obtiene la misma RNMPD pero sin una dependencia exponencial respecto al incremento del número de atributos utilizados para representar a los patrones de entrenamiento.

3.1 Metodología

Para llevar a cabo el objetivo general de esta investigación se propone la siguiente metodología con una RNMPD, compuesta por cinco fases, las cuales se explican de la siguiente manera:

1. *Análisis de los datos.* En primer lugar, es importante realizar una investigación y llevar a cabo un *análisis* exhaustivo de la RNMPD, con la finalidad de conocer a detalle el funcionamiento de la técnica, el diseño de su arquitectura, su eficiencia, y el rendimiento que ha tenido en otros casos. Se decidió trabajar con esta red, debido a que los métodos de entrenamiento existentes presentan diversos inconvenientes como el traslape de regiones cuando se trata de problemas en ambientes no controlados. En cambio, la RNMPD es capaz de resolver problemas de múltiples clases con una sola neurona. Otra ventaja, es que el algoritmo tiene un número menor de pasos y los hipercubos obtenidos no se traslapan entre sí.
2. *Definición de los datos de entrada.* Una vez obtenido el diseño de la nueva red y se conozca el funcionamiento que tendrá ante datos de la vida real, se lleva a cabo el desarrollo del algoritmo de entrenamiento y prueba, pero previo a esto, es necesario poseer un archivo con el conjunto de datos de entrada y otro con datos de prueba diferentes a los de entrada para entrenar y probar la red. Para ello es necesario apoyarse de herramientas tecnológicas, para este caso en particular, se utilizó la

aplicación para dispositivos móviles: “*Queiloquisis: Detección y Análisis facial*”, dicha aplicación permite obtener los datos de los rasgos faciales en personas con labio leporino.

3. *Entrenamiento*: El entrenamiento de las redes neuronales es un caso de aprendizaje supervisado, se dice que es así cuando el objetivo es aprender una función a partir de ejemplos de sus entradas y salidas. Para llevar a cabo esto, se realiza la descripción detallada del algoritmo de entrenamiento y se mencionan sus características principales. Se llevó a cabo la prueba y el entrenamiento de los datos de personas con dismorfia facial, de los datos obtenidos se promedió el porcentaje de error y el porcentaje de datos correctos para posteriormente compararlos con los otros métodos clasificadores.
4. *Desempeño*. se requiere de una aplicación que permita conocer el rendimiento de las redes neuronales a *comparar*. En este caso se utilizó *Weka* como máquina de aprendizaje, lo que permitió obtener resultados de entrenamiento y prueba sobre los diferentes métodos clasificadores a comparar.
5. *Comparación*. El método comparativo consiste en poner dos o más fenómenos, uno al lado del otro, para establecer sus similitudes y diferencias y de ello sacar conclusiones que definan un problema o que establezcan caminos futuros para mejorar el conocimiento de algún tema en específico, en la presente tesis se realizará la comparación del desempeño de la RNMPD con el de otros métodos clasificadores: SMO, IBK y Multilayer Perceptron, para conocer la eficacia que tiene ante problemas de distrofia facial.

3.2 Algoritmo del clasificador SMO

En este tipo de redes el entrenamiento o aprendizaje es diferente al de las redes con entrenamiento supervisado. A la red no se le suministra junto a los patrones de entrenamiento, una salida deseada. Lo que hará la red es encontrar regularidades o clases en los datos de entrada, y modificar sus pesos para ser capaz de reconocer estas regularidades o clases.

La arquitectura típica de este tipo de mapas es la de la Figura 7 :

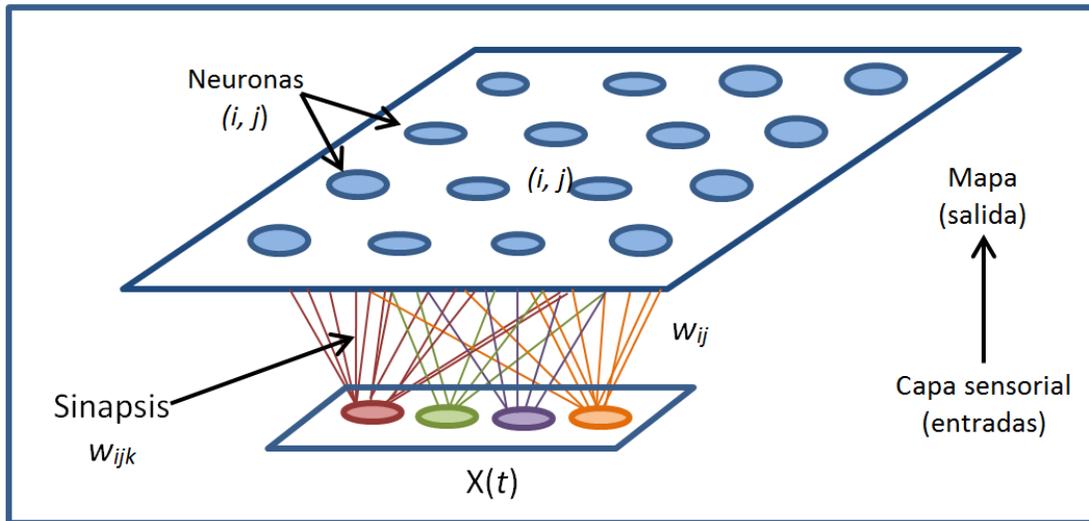


Figura 7 Arquitectura del clasificador SMO

Como se puede apreciar es una red de tipo unidireccional. La red se organiza en dos capas, siendo la primera capa la formada por las neuronas de entrada. La segunda capa consiste en un array de neuronas de dos dimensiones. Como se necesitan dos índices para etiquetar cada neurona, los pesos sinápticos asociados a cada neurona tendrán tres índices (i, j, k) donde (i, j) indican la posición de la neurona en la capa y k , la componente o conexión con cierta neurona de entrada.

En cuanto al entrenamiento, este es un ejemplo de red que utiliza un aprendizaje de tipo no supervisado. Además, cada neurona utiliza como regla de propagación una distancia de su vector de pesos sinápticos al patrón de entrada. Otros conceptos importantes que intervienen en el proceso de aprendizaje son los conceptos de neurona ganadora y vecindad de la misma. Un algoritmo de aprendizaje muy usado con este tipo de redes es el algoritmo de Kohonen que se describe como sigue:

1. Inicialización de los pesos w_{ijk} . Hay varias opciones posibles.
2. Elección de un patrón de entre el conjunto de patrones de entrenamiento.
3. Para cada neurona del mapa, calcular la distancia euclídea (Ver Ecuación (9)) entre el patrón de entrada x y el vector de pesos sinápticos.

$$d^2(w_{ij}, x) = \sum_k (w_{ijk} - x_k)^2 \quad \text{Ecuación (9)}$$

4. Evaluar la neurona ganadora, es decir aquella cuya distancia es la menor de todas
5. Actualizar los pesos sinápticos (Ver Ecuación (10)) de la neurona ganadora y de sus vecinas según la regla:

$$\delta w_{ijk}(t) = \alpha(t) \cdot h(|i - g|, t) \cdot (x_k(t) - w_{ijk}(t)) \quad \text{Ecuación (10)}$$

Donde $\alpha(t)$ es un factor llamado ritmo de aprendizaje que da cuenta de la importancia que la diferencia entre el patrón y los pesos tiene en el ajuste de los mismos a lo largo del proceso de aprendizaje. Hay varias posibilidades para esta función, desde un constante hasta algún tipo de función monótona decreciente con el tiempo. h es una función de vecindad que nos indica en qué medida se modifican los pesos de las neuronas vecinas. Con esto quiere decir que cuando la neurona ganadora modifica sus pesos, la vecindad de esta neurona lo hace también, en mayor ó menor medida según sea la forma funcional de h . En general, las funciones empleadas para h tienen un máximo en $|i - j| = 0$ y decrecen más o menos rápido a medida que esta distancia aumenta.

6. Lo usual es fijar un número de iteraciones antes de comenzar el aprendizaje. Si no se llegó al número de iteraciones establecido previamente, se vuelve al paso 2. Sobre este número de iteraciones necesario, se suelen tomar criterios como el número de neuronas en el mapa.

3.3 Algoritmo del clasificador Ibk

K-Nearest Neighbors (KNN) es un método de clasificación supervisado. También puede utilizarse en regresión. KNN sirve para estimar una función de densidad $F(x/C_j)$ que predice el valor x para la clase C_j .

La idea que fundamenta este algoritmo es que el nuevo objeto se clasificará en la clase más frecuente de sus K vecinos más próximos (Ver Figura 8).

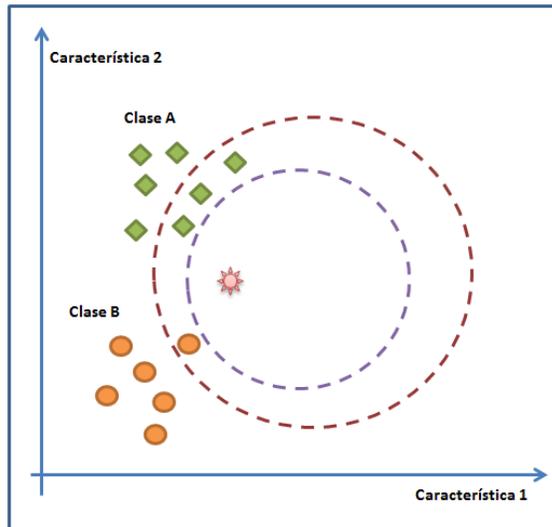


Figura 8 Clasificación con KNN

Para resolver los casos de empate, se puede añadir alguna regla heurística como puede ser el vecino más próximo. Para clasificación con KNN:

1. La tupla (punto) desconocida es asignado a la clase más común de los k vecinos más próximos. Si $k=1$, entonces se asignará al vecino más próximo.
2. Si k es demasiado pequeño, entonces el resultado es muy sensible a puntos ruidosos.
3. Pero si k es demasiado grande, entonces la vecindad del punto desconocido incluirá muchos puntos de otras clases lejanas.
4. Regla: k debe ser grande para disminuir la probabilidad de una mala clasificación, pero pequeño en comparación con el número de puntos.

KNN pierde precisión si se utilizan datos ruidosos o con atributos irrelevantes. Entonces es interesante sopesar los vecinos con la distancia que lo separa de la tupla desconocida.

$$y = \sum_{i=1}^k w_i \cdot y_i \text{ con } w_i = \frac{1}{d(x_{test}, x_i)^2} \quad \text{Ecuación (11)}$$

Si se utiliza KNN con datos categóricos, el algoritmo devuelve la categoría a la cual debería pertenecer la tupla desconocida. Si se utiliza KNN con datos continuos, el algoritmo devuelve la media de los valores de los vecinos.

El uso de KNN en clasificación se fundamenta en el uso del voto (mayoría) para decidir el valor más adecuado. El voto puede ser con pesos o sin ellos. Observación: si la clasificación es binaria, entonces es preferiblemente elegir k impar para evitar empates.

La elección de la métrica de la distancia es crítica para el rendimiento del algoritmo.

$$D(X_1, X_2) = \sqrt{\sum_{i=1}^n (X_{1i} - X_{2i})^2}$$

Ecuación (12)

Además hay que tener cuidado si tiene atributos con rangos muy grandes (por ejemplo, ingresos) y otros con rangos pequeños (por ejemplo atributo binario), ya que unos enmascararan a los otros. La solución es normalizar adecuadamente todos los atributos.

$$v' = \frac{v - v_{min}}{v_{max} - v_{min}}$$

Ecuación (13)

Otros algoritmos clasificatorios basan la clasificación de cada nuevo caso en dos tareas: primero se induce el modelo clasificatorio (inducción), y posteriormente, se deduce la clase del nuevo caso (deducción). Sin embargo, en KNN ambas tareas están unidas (transducción)

3.4 Algoritmo del clasificador Multilayer Perceptron

La arquitectura de Perceptron multicapa se caracteriza porque tiene sus neuronas agrupadas en capas de diferentes niveles. Cada una de las capas está formada por un conjunto de neuronas y se distinguen tres tipos de capas diferentes: la capa de entrada, las capas ocultas y la capa de salida (Ver Figura 9).

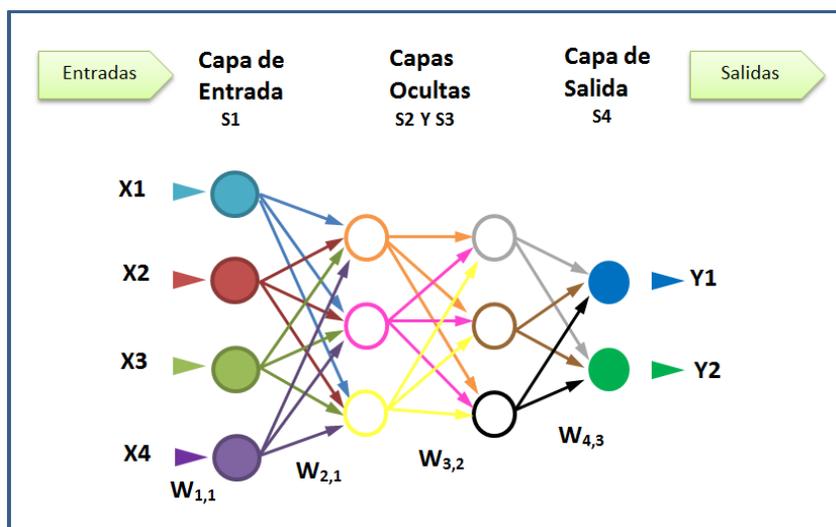


Figura 9 Arquitectura Multilayer Perceptron

Las neuronas de la capa de entrada no actúan como neuronas propiamente dichas, sino que se encargan únicamente de recibir las señales o patrones del exterior y propagar dichas señales a todas las neuronas de la siguiente capa. La última capa actúa como salida de la red, proporcionando al exterior la respuesta de la red para cada uno de los patrones de entrada. Las neuronas de las capas ocultas realizan un procesamiento no lineal de los patrones recibidos.

Las conexiones del Perceptron multicapa siempre están dirigidas hacia adelante, es decir, las neuronas de una capa se conectan con las neuronas de la siguiente capa, de ahí que reciban también el nombre de redes alimentadas hacia adelante o redes *feedforward*. Las conexiones entre las neuronas de la red llevan también asociado un umbral, que en el caso del Perceptron multicapa suele tratarse como una conexión más a la neurona, cuya entrada es constante e igual a 1. Generalmente, todas las neuronas de una capa están conectadas a todas las neuronas de la siguiente capa. Se dice entonces que existe conectividad total o que la red está totalmente conectada.

El Perceptrón multicapa define una relación entre las variables de entrada y las variables de salida de la red. Esta relación se obtiene propagando hacia adelante los valores de las variables de entrada. Para ello, cada neurona de la red procesa la información recibida por sus entradas y produce una respuesta o activación que se propaga, a través de las conexiones correspondientes, hacia las neuronas de la siguiente capa. A continuación, se muestran las expresiones para calcular las activaciones de las neuronas de la red. Sea un Perceptron multicapa con C capas – $C - 2$ capas ocultas- y n_c neuronas en la capa c , para $c = 1, 2, \dots, C$.

Sea $W^c = (w_{ij}^c)$ la matriz de pesos donde w_{ij}^c representa el peso de la conexión de la neurona i de la capa c para $c = 2, \dots, C$. Denotaremos a_i^c a la activación de la neurona i de la capa c . Estas activaciones se calculan del siguiente modo:

1. Activación de las neuronas de la *capa de entrada* (a_i^1). Las neuronas de la capa de entrada se encargan de transmitir hacia la red las señales recibidas desde el exterior. Por lo tanto:

$$a_i^1 = x_i \text{ para } i = 1, 2, \dots, n_1 \quad \text{Ecuación (14)}$$

donde $X = (x_1, x_2, \dots, x_{n_1})$ representa el vector o patrón de entrada a la red.

2. Activación de las neuronas de la *capa oculta* c (a_i^c). Las neuronas ocultas de la red procesan la información recibida aplicando la función de activación f a la suma de los productos de las activaciones que recibe por sus correspondientes pesos, es decir:

$$a_i^c = f\left(\sum_{j=1}^{n_{c-1}} w_{ji}^{c-1} a_j^{c-1} + u_i^c\right) \text{ para } i = 1, 2, \dots, n_c \text{ y } c = 2, 3, \dots, C - 1 \quad \text{Ecuación (15)}$$

donde a a_j^{c-1} son las activaciones de las neuronas de la capa $c - 1$.

3. Activación de las neuronas de la *capa de salida* (a_i^c). Al igual que en el caso anterior, la activación de estas neuronas viene dada por la función de activación f aplicada a la suma de los productos de las entradas que recibe por sus correspondientes pesos:

$$y_i = a_i^c = f\left(\sum_{j=1}^{n_{c-1}} w_{ji}^{c-1} a_j^{c-1} + u_i^c\right) \text{ para } i = 1, 2, \dots, n_c \quad \text{Ecuación (16)}$$

donde $Y = (y_1, y_2, \dots, y_{n_c})$ es el vector de salida de la red.

La función f es la llamada *función de activación*. Para el Perceptron multicapa, las funciones de activación más utilizadas son la función sigmoïdal y la función tangente hiperbólica. Dichas funciones poseen como imagen un intervalo continuo de valores dentro de los intervalos $[0, 1]$ y $[-1, 1]$, respectivamente, y vienen dadas por las siguientes ecuaciones:

Función sigmoïdal:

$$f_{sigm}(x) = \frac{1}{1+e^{-x}} \quad \text{Ecuación (17)}$$

Función tangente hiperbólica:

$$f_{thip}(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad \text{Ecuación (18)}$$

Ambas son funciones crecientes con dos niveles de saturación: el máximo, que proporciona salida 1, y el mínimo, salida 0 para la función sigmoïdal y salida -1, para la

tangente hiperbólica, como se observa en la figura 3.1. En algunas ocasiones, la función de activación en el Perceptron multicapa es común a todas las neuronas de la red y es elegida por el diseñador, elección que se realiza únicamente basándose en los valores de activación que se desee que alcancen las neuronas.

De las ecuaciones 3.1, 3.2 y 3.3, se observa que el perceptron multicapa define, a través de sus conexiones y neuronas, una función continua no lineal del espacio R^{n1} -espacio de los patrones de entrada- al espacio R^{nC} -espacio de los patrones de salida-. Se puede escribir, por tanto, que:

$Y = F(X, W)$ (3.6) donde Y es el vector formado por las salidas de la red, X es el vector de entrada a la red, W es el conjunto de todos los parámetros de la red -pesos y umbrales- y F es una función continua no lineal dada por las ecuaciones 3.1, 3.2 y 3.3

3.5 Algoritmo de entrenamiento y ejemplo con la RNMPD

Las redes neuronales morfológicas difieren de los modelos clásicos en la manera en que modelan la interacción entre las señales de entrada y los diferentes parámetros de la neurona. En particular, las señales interactúan con los pesos sinápticos de manera aditiva y no multiplicativa; así pues, el procesamiento de la información tanto en las dendritas como en el cuerpo celular se realiza haciendo uso de operadores morfológicos (máximo y mínimo) y no sumas como en el caso clásico.

Las redes neuronales morfológicas utilizan operaciones de tipo *lattice*, \vee (máximo) o \wedge (mínimo), y $+$ para los semi-anillos $(\mathbb{R}_{-\infty}, \vee, +)$ o $(\mathbb{R}_{\infty}, \wedge, +)$ donde $\mathbb{R}_{-\infty} = \mathbb{R} \cup \{-\infty\}$ y $\mathbb{R}_{\infty} = \mathbb{R} \cup \{\infty\}$. El cálculo de la neurona en una red neuronal morfológica para una entrada $\chi = (\chi_1, \chi_2, \dots, \chi_n)$ está dado por las siguientes ecuaciones:

$$\tau_j(x) = a_j \bigvee_{i=1}^n b_{ij}(x_i + w_{ij}) \quad \text{Ecuación (19)}$$

$$\tau_j(x) = a_j \bigwedge_{i=1}^n b_{ij}(x_i + w_{ij}) \quad \text{Ecuación (20)}$$

en donde $b_{ij} = \pm 1$ denota si la i – esima neurona ocasiona excitación o inhibición en la j – esima neurona, $a_j = \pm 1$ denota la respuesta a la salida (excitación o inhibición) de la j – esima neurona a las neuronas con las cuales sus axones tienen contacto y w_{ij} denota la fuerza sináptica entre la i – esima neurona y la j – esima neurona. Los parámetros b_{ij} y a_j toman el valor de $+1$ ó -1 dependiendo de si la i – esima neurona de entrada causa excitación o inhibición a la j – esima neurona.

El cálculo realizado por la k – esima dendrita puede ser expresado mediante la siguiente formula:

$$D_k(x) = a_k \bigwedge_{i \in I} \bigwedge_{l \in L} (-1)^{1-l} (x_i + w_{iK}^l) \quad \text{Ecuación (21)}$$

en donde $\chi = (\chi_1, \chi_2, \dots, \chi_n) \in \mathbb{R}^n$ corresponde a la entrada de las neuronas, $I \subseteq \{1, \dots, n\}$ denota a el conjunto de todas las neuronas de entrada N_i con fibras terminales que hacen sinapsis en la k – esima dendrita de la neurona morfológica $NL \subseteq \{0,1\}$ corresponde a el conjunto de las fibras terminales de la i – esima neurona que hace sinapsis con la k – esima dendrita de N , y $a_k \in \{-1,1\}$ denota la repuesta de excitación o inhibición de la k – esima dendrita.

Claramente, $I \neq \emptyset$ y $L \neq \emptyset$ ya que hay al menos una fibra axonal proveniente de al menos una de las neuronas de entrada con la sinapsis de la dendrita K . La función de activación usada en las redes neuronales morfológicas es una función de limite duro, la cual asigna 1 si la entrada es mayor o igual a 0 y asigna 0 si la entrada es menor que 0.

Una problemática clave en el diseño de una red neuronal artificial con procesamiento dendral (RNMPD) es el entrenamiento; esto es, la selección del número de dendritas y los valores de los pesos sinápticos para cada una de ellas.

La estrategia de entrenamiento de eliminación inicia con una región que es lo suficientemente grande para contener todos los patrones de entrenamiento de una clase, seguido de la eliminación de los patrones ajenos que se encuentran en esa región. La eliminación se logra mediante la construcción de hipercubos más pequeños alrededor de los patrones ajenos y el establecimiento de los parámetros de la red de tal manera que

estas regiones se excluyan. La eliminación se realiza mediante el cálculo de la interacción de las regiones reconocidas por las dendritas

A continuación se dará un ejemplo simple con el cual se explicará el algoritmo. El ejemplo consta de tres clases con dos atributos, en la **Figura 10** Se muestra los patrones de ejemplo, los patrones C_1 son los puntos rojos, los patrones de C_2 son los puntos verdes y los patrones C_3 son los puntos azules.

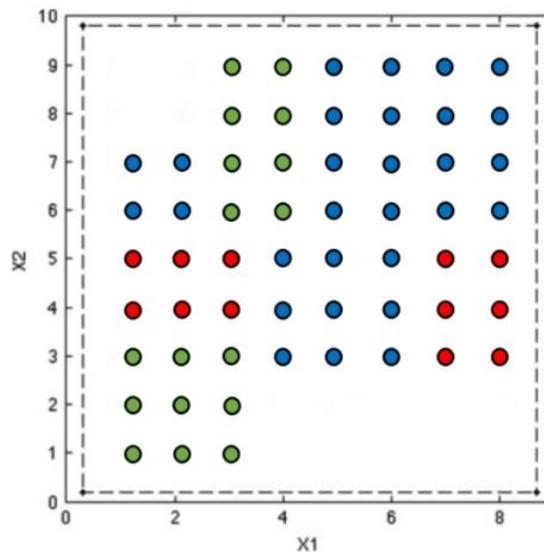


Figura 10 Ejemplo de tres atributos

Dadas p clases de patrones $C^k, K = 1, 2, \dots, p$, cada uno con n atributos, el algoritmo a aplicar es el siguiente:

1. Seleccionar los patrones de todas las clases y abrir un hiper-cubo HC^n (donde n es el número de atributos) con un tamaño tal que todos los elementos de las clases queden dentro del hiper-cubo. El hiper-cubo debe tener un margen M de cada lado, para tener una mejor tolerancia al ruido al momento de clasificar.
2. Dividir el hiper-cubo en 2^n hiper-cubos más pequeños y verificar si se satisface el criterio de paro. El cual implica, que cada hiper-cubo encierre patrones que pertenezcan a una misma clase. Si es el caso, etiquetar el hiper-cubo con el nombre de la clase correspondiente y parar el proceso de aprendizaje, seguir con el paso 4. En el ejemplo, la primera división de la caja se muestra en la **Figura 11**.

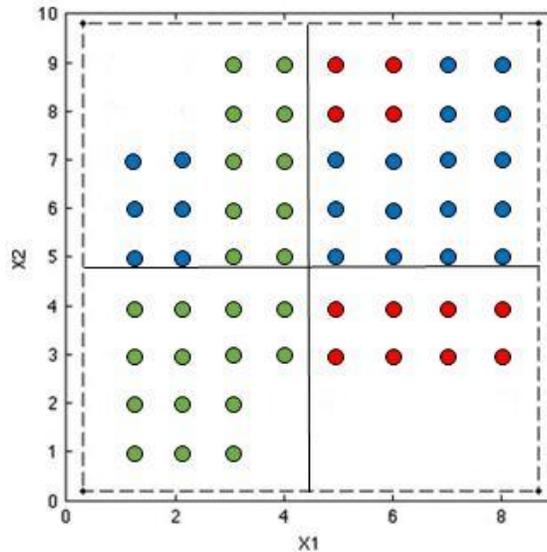


Figura 11 Primera división ejecutada por el algoritmo de entrenamiento

3. El paso 3 consta de dos etapas:

3.1. Si al menos uno de los hiper-cubos generados (HC^n) tiene patrones de más de una clase, dividir el hiper-cubo en 2^n hiper-cubos más pequeños. Repetir de manera iterativa el proceso de verificación dentro de cada nuevo hiper-cubo generado, hasta que el criterio de paro se satisfaga. En la **Figura 12** se muestran los hiper-cubos generados por el algoritmo de entrenamiento.

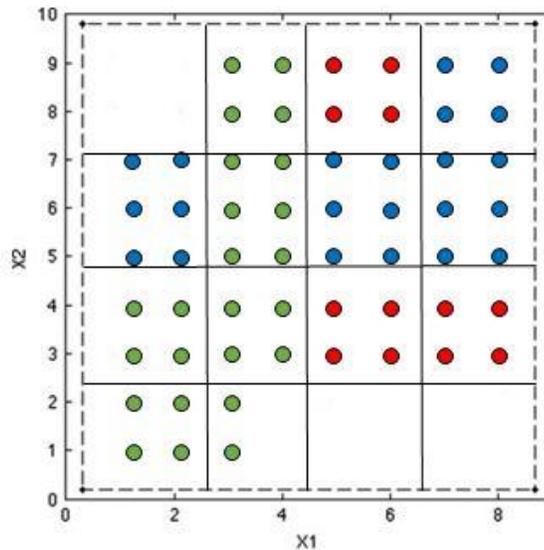


Figura 12 Cajas generadas después del proceso iterativo de división

3.2 Una vez que todos los hiper-cubos fueron generados, si dos o más hiper-cubos de la misma clase comparten un lado en común serán agrupados dentro de una misma

región. En la Figura 13 se muestra cómo es que se aplica este proceso de simplificación, el cual provoca que el número de hiper-cubos se reduzca.

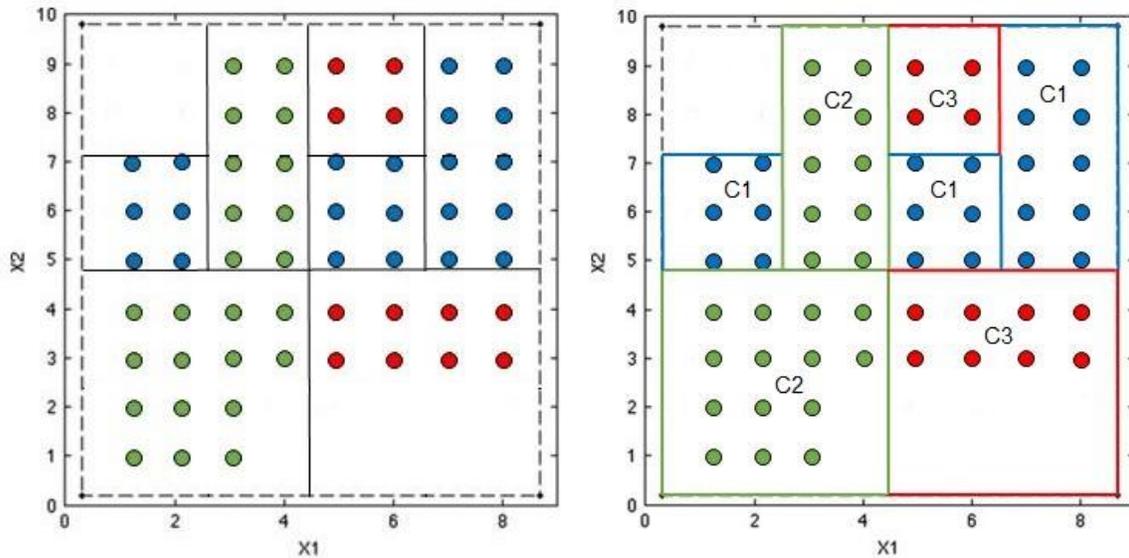


Figura 13 a) Cajas agrupadas dentro de una misma región

b) Cajas obtenidas después de aplicar el algoritmo de simplificación

4.- Con base en las coordenadas de cada eje, calcular los pesos para cada hiper-cubo que encierra los patrones pertenecientes de la clase C^k , tomando en cuenta solo aquellos hiper-cubos que encierren los elementos de la clase C^k .

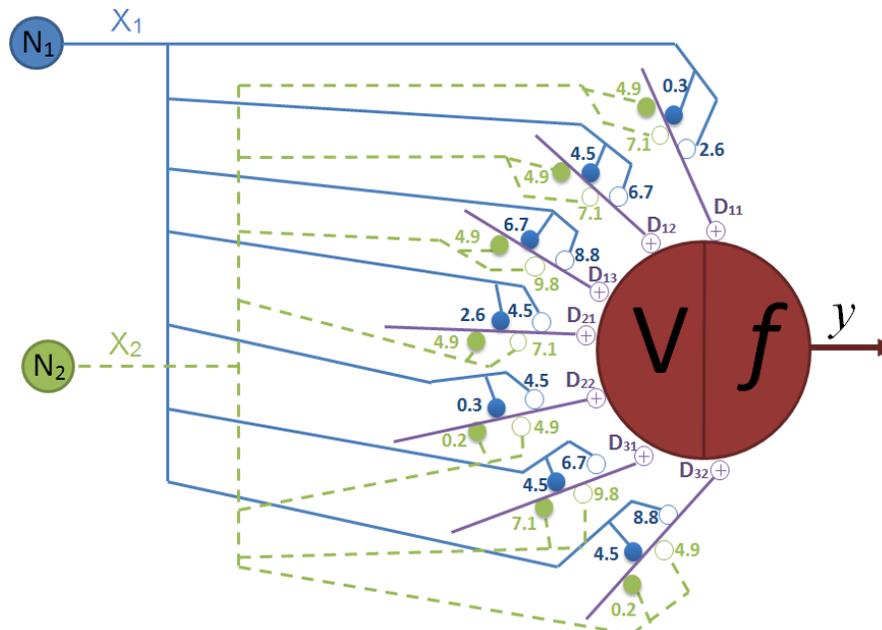


Figura 14 Diseño de una Red Neuronal Morfológica con Procesamiento Dendral

Una vez hecho lo anterior, se procede a diseñar la RNMPD, tal y como se muestra en la Figura 14 la cual tienen una capa de entrada que separa las tres clases C^1, C^2 y C^3 . Las neuronas de la capa de entrada están conectadas a la siguiente capa por medio de las dendritas. Los círculos blancos y negros, denotan las conexiones de excitación y de inhibición, respectivamente. La interpretación geométrica del cálculo realizado por una dendrita es que cada dendrita determina un hiper-cubo el cual puede ser definido por una sola dendrita por medio del valor de sus pesos w_{ij} como se muestra en el ejemplo:

Para probar el diseño de la red resultante, se hará uso de dos patrones de prueba $(\widetilde{X}_1) = \begin{pmatrix} 1.5 \\ 6.2 \end{pmatrix}$ de la clase $C1$ y $(\widetilde{X}_2) = \begin{pmatrix} 6.5 \\ 1.8 \end{pmatrix}$ de la clase $C3$. Cuando la Ecuación (21) se aplica a la primera dendrita, se obtienen los siguientes resultados:

$$\begin{aligned} D_{11}(\widetilde{X}_1) &= D_{11} \begin{pmatrix} 1.5 \\ 6.2 \end{pmatrix} = [(1.5 - 0.3)] \wedge -[(1.5 - 2.6)] \wedge [(6.2 - 4.9)] \wedge -[(6.2 - 7.1)] \\ &= 1.2 \wedge 1.1 \wedge 1.3 \wedge 0.9 \\ &= 0.9 \end{aligned}$$

$$\begin{aligned} D_{11}(\widetilde{X}_2) &= D_{11} \begin{pmatrix} 6.5 \\ 1.8 \end{pmatrix} = [(6.5 - 0.3)] \wedge -[(6.5 - 2.6)] \wedge [(1.8 - 4.9)] \wedge -[(1.8 - 7.1)] \\ &= 6.2 \wedge -3.9 \wedge -3.1 \wedge 5.3 \\ &= -3.9 \end{aligned}$$

De la misma manera, se calculan todas las otras dendritas;

$$\widetilde{X}_1: D_{12} = -3, D_{13} = -5.2, D_{21} = -1.1, D_{22} = -1.3, D_{31} = -3, D_{32} = -3$$

Y para

$$\widetilde{X}_2: D_{12} = -3.1, D_{13} = -3.1, D_{21} = -3.1, D_{22} = -2, D_{31} = -5.3, D_{32} = 1.6$$

Con estos valores y por medio de la (primera ecuación de este capítulo), se obtiene la siguiente clasificación:

$$\begin{aligned} \tau(\widetilde{X}_1): &(D_{11} \vee D_{12} \vee D_{13} \vee D_{21} \vee D_{22} \vee D_{31} \vee D_{32}) \\ &= (0.9 \vee -3 \vee -5.2 \vee -1.1 \vee -1.3 \vee -3 \vee -3) = 0.9 \end{aligned}$$

$$\begin{aligned}\tau(\widetilde{X}_2): (D_{11} \vee D_{12} \vee D_{13} \vee D_{21} \vee D_{22} \vee D_{31} \vee D_{32}) \\ = (-3.9 \vee -3.1 \vee -3.1 \vee -3.1 \vee -2 \vee -5.3 \vee 1.6) = 1.6\end{aligned}$$

Por lo tanto $\tau(\widetilde{X}_1) = 0.9 \geq 0$ o corresponde a D_{11} (índice de C^1) así $y(\widetilde{X}_1) = 1$, el patrón de entrada se clasifica en la clase C^1 y como se esperaba. Además, $\tau(\widetilde{X}_2) = 1.6 \geq 0$ corresponde a D_{32} (índice de C^3) así $y(\widetilde{X}_2) = 1$, el patrón de entrada se clasifica en la clase C^3 . Si existe el caso de que el valor de la neurona (τ) no es mayor o igual a cero, entonces el patrón no se clasifica en ninguna clase.

3.6 Preprocesamiento de los datos con la RNMPD

Para el procesamiento de los datos fue necesario definir previamente ciertas características, como el tipo de imagen, los rasgos a evaluar, y la aplicación de reconocimiento facial que se adaptará a las necesidades del presente proyecto.

3.6.1 Características de las imágenes

Las imágenes, como dibujos y fotografías, se graban en diferentes formatos para su uso en computadoras.

Dados los grandes avances en la tecnología y el mundo digital, actualmente las imágenes son de mayor resolución que aquellas utilizadas en los comienzos del estudio de la biometría. Por este motivo, para *la presente investigación se utiliza imágenes con formato JPEG*, ya que es un algoritmo diseñado para comprimir imágenes con 24 bits de profundidad o en escala de grises. Normalmente se le llama JPG debido a la extensión que tiene en sistemas operativos que sólo aceptan tres letras de extensión. Una de las características que hacen muy flexible el JPEG (JPG) es el poder ajustar el grado de compresión. Si especificamos una compresión muy alta se perderá una cantidad significativa de calidad, pero obtendremos ficheros extremadamente pequeños. Con una cantidad de compresión baja obtenemos una calidad muy parecida a la del original, y un fichero pequeño [104].

Las imágenes en JPG están comprimidas, por lo tanto ocupan mucho menos espacio que sus versiones sin comprimir, por cierto, una imagen sin comprimir se guarda en formato BMP.

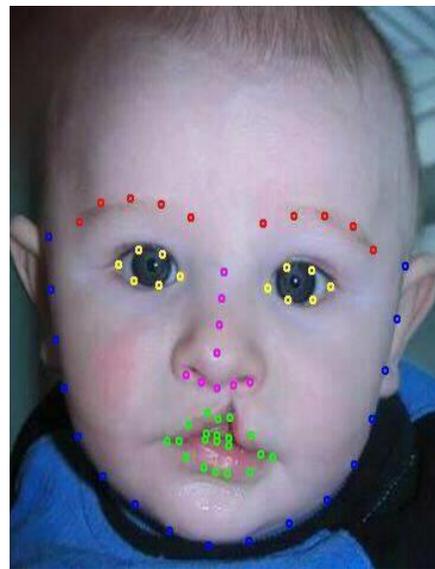
La manera en que se comprime una imagen JPG es deshaciéndose de cierta información, al tener menos datos que guardar se hace más ligera, pero esto lleva una pérdida de calidad. Normalmente no se le nota esa calidad inferior, a menos que le pongamos zoom a la imagen y la veamos al 200% de su tamaño, entonces sí que se nota, pero para su uso normal al 100% es casi imperceptible. La compresión es una variable que se puede controlar al momento de guardar la imagen, si le ponemos una calidad del 90% la pérdida de calidad es difícilmente distinguible, sin embargo su tamaño es menos. Si se comprime al 50% la calidad aún no es tan mala a simple vista y su tamaño se reduce considerablemente [105].

Las cámaras fotográficas digitales, y también los celulares con cámara, usan el formato JPG precisamente por esa razón, por el poco espacio que ocupan.

Para las imágenes de la base de datos se tomaron en cuenta aspectos como la luz y la postura de cada una de ellas, para que no se generaran errores que pudieran entorpecer el funcionamiento de la red.



Figura 15 a) Imagen que no presenta dismorfia facial



b) Imagen que presenta dismorfia facial

3.6.2 Características de rasgos descriptores de la red

Para poder llevar a cabo el entrenamiento de la Red Neuronal, es importante contar con una base de datos con casos de personas con y sin dismorfia.

Previo a esto, fue necesario apoyarse de una aplicación de reconocimiento facial para recolectar los datos almacenados en la base de datos, y de esta manera obtener las coordenadas de los atributos (rasgos faciales).

Los sistemas de reconocimiento facial permiten identificar a una persona analizando las características biométricas de su rostro. Para llevar a cabo el objetivo de esta investigación, se utilizó la aplicación “*Queiloquisis: Detección y Análisis facial*” [39], ésta fue diseñada para dispositivos Android y para su desarrollo, se utilizó la librería *DLIB*, ya que contiene algoritmos de aprendizaje de máquina y herramientas para crear software complejo que permita resolver problemas del mundo real. Se utiliza en la industria y el mundo académico en una amplia gama de dominios, incluyendo la robótica, dispositivos integrados, teléfonos móviles y grandes entornos de computación de alto rendimiento. Las licencias de código abierto de *DLIB* permiten usarlo en cualquier aplicación, de forma gratuita.

El motivo por el que se escogió esta aplicación y no otra existente en el mercado, es porque la mayoría utilizan la librería de OpenCV, que aunque es buena, identifica una menor cantidad de puntos que la librería *DLIB* que identifica 68 puntos, que están distribuidos de la siguiente manera:

- Mejillas y Mentón: 0 a 16 (representados en la imagen por el color azul).
- Cejas: 17 a 26 (representados en la imagen por el color rojo).
- Nariz: 27 a 35 (representados en la imagen por el color rosa).
- Ojos: 36 a 47 (representados en la imagen por el color amarillo).
- Boca: 48 a 67 (representados en la imagen por el color verde).

De los rasgos (0-67) identificados con la aplicación “*Queiloquisis: Detección y Análisis facial*”, solo se utilizarían 11, que corresponden a la parte de la boca (49, 50, 51, 52, 53, 61, 62, 63, 65, 66 y 67) (Ver Figura 16).

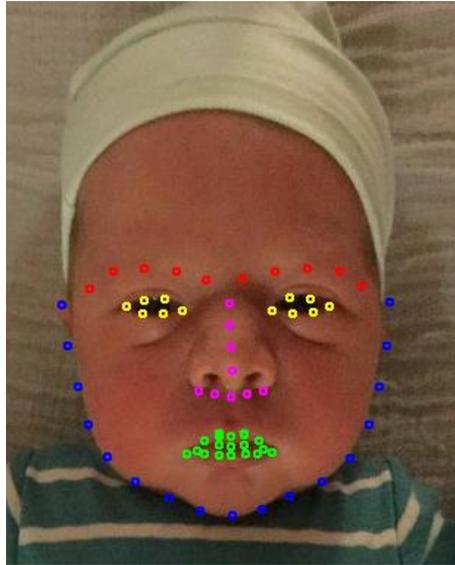


Figura 16 Puntos característicos del rostro en la aplicación: “Queiloquisis: Detección y Análisis facial”

El significado de cada rasgo

La altura facial se divide en tres partes iguales (Véase Figura 17) [105]:

1. El primer tercio va desde el Triquion (Tr) a la Glabella (G).
2. El tercio medio desde la (G) al punto Subnasal (Sn).
3. El tercio inferior de la cara corresponde del (Sn) al Mentón (Me).

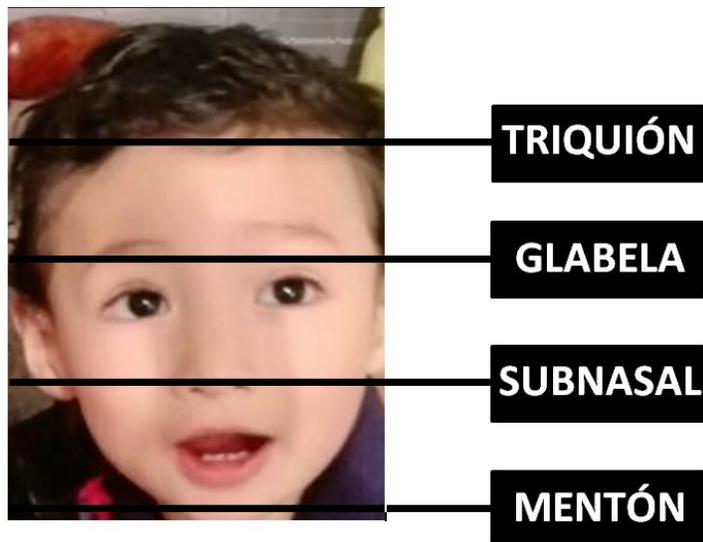


Figura 17 Altura facial dividida en tres partes iguales.

Debido a que el proyecto es referente a las dismorfias que existen en los labios, en éste caso solo nos enfocaremos en la tercera parte de la cara, que va del punto Subnasal al Mentón.

La región labial está situada por debajo de la pirámide nasal, entre ambas mejillas, y por encima de la región mentoniana. Los labios son dos repliegues músculos membranosos, inferior y superior; que forman la pared anterior del vestíbulo de la boca.

El labio superior comprende el bermellón, o labio propiamente dicho, y la zona que se encuentra entre este, la base de la nariz y los surcos nasogenianos. El inferior está formado igualmente por el bermellón y la zona de piel limitada por la continuación de los surcos nasogenianos e, inferiormente, por el comienzo del mentón, en el surco mento-labial. Su músculo más importante es el orbicular de los labios (4), que cierra el esfínter oral y proporciona la competencia labial, fundamental para una correcta respiración nasal. Los músculos elevadores del labio superior son: el elevador del labio superior (3), el cigomático mayor (1) y el cigomático menor (2). Otros músculos que actúan en los labios son el triangular de los labios (8), el risorio (5) y el buccinador (6). En el labio inferior la elevación y protrusión de la parte central es producida por los músculos mentonianos (10), mientras que su descenso se debe a la acción de los músculos cuadrados del mentón (9) que nacen del borde inferior de la mandíbula (Ver Figura 18) [106].

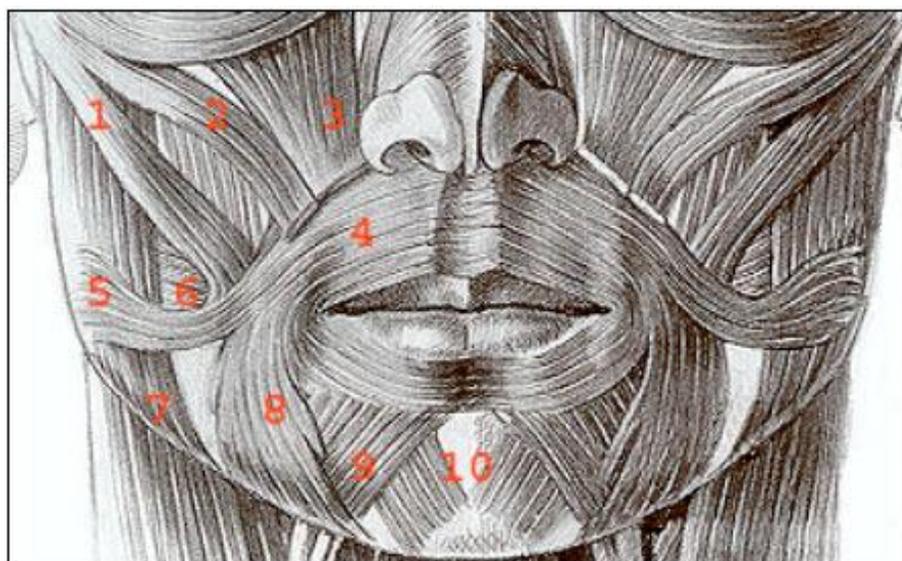


Figura 18 Músculos de los labios [107]

3.7 Optimización y normalización de los datos

Para generar la base de datos con la que se va a entrenar la red como ya se mencionó se utilizó la aplicación “Queiloquisis; Detección y Análisis facial”, guardando las coordenadas de los puntos detectados en un archivo Excel, después de se procede a realizar la optimización de los datos mediante una serie de pasos.

1. *Guardar coordenadas:* Después de haber tomado la fotografía se almacenan las coordenadas en x y y de los 68 puntos detectados. Fue necesario dividirlos en lado derecho y lado izquierdo tomando solo en cuenta los 9 puntos de interés antes mencionados ya que el objetivo principal de este trabajo es el de medir el grado de asimetría que tiene un rostro. De esta manera los puntos son:

- Lado Derecho (*LD*) (49,50,61)
- Lado Izquierdo (*LI*) (53,52,63)
- Puntos del Centro (*PC*) (51,62)
- *Punto central Nariz* (30)

En la Tabla 2 se muestran las coordenadas X y Y de los puntos antes mencionados:

Tabla 2 Coordenadas de las fotografías

NOMBRE	Punto	Coordenadas	
		X	Y
LADO DERECHO	49	238	369
	50	250	364
	61	250	372
LADO IZQUIERDO	53	277	372
	52	265	365
	63	265	373
CENTRO	51	258	367
	62	258	374
PUNTO NARIZ	30	259	316

2. *Convertir en radianes:* Para trabajar con números más precisos las coordenadas obtenidas en el paso anterior se convirtieron a grados en radianes. Para todas las conversiones se toma como referencia o punto de partida el Punto Central Nariz (30) ya

que es el único punto que esta fijo en todo momento y como su nombre lo dice, es el centro de la cara.

En la Figura 19 se muestra la manera en que se mide la distancia de un punto cualquiera respecto al punto central de la nariz. Para saber el valor de dicha distancia es necesario aplicar la fórmula de la Ecuación (22) en cada punto:

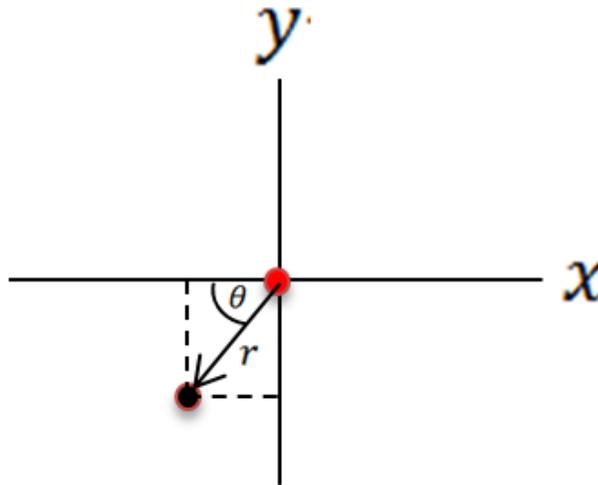


Figura 19 Distancia respecto al punto central de la nariz

$$r = \sqrt{x^2 + y^2}$$

Ecuación (22)

Y para el ángulo se realiza a formula de la Ecuación (23):

$$\theta = \text{arc tan} \frac{y}{x}$$

Ecuación (23)

Para convertir los ángulos obtenidos a radianes, se puede hacer directamente desde la calculadora con la función *rad* o multiplicar el resultado por lo que equivale un radian. Los resultados de ambos lados y de los puntos del centro después de haber aplicado la formula a cada coordenada están descritos en la Tabla 3.

Tabla 3 Resultados después de aplicar la fórmula a cada coordenada

NOMBRE	Pto.	Conversión a Radianes
LADO DERECHO	49	0.006
	50	0.003
	61	0.004
LADO IZQUIERDO	53	0.005
	52	0.002
	63	0.003
CENTRO	51	0.004
	62	0.004

3. *Restas*: Finalmente para poder medir el grado de asimetría que hay entre un lado y otro, se hizo una resta correspondiente a cada punto de cada lado, considerando que los valores de tales posiciones ya están convertidos en radianes, se procede a hacer las restas de los puntos de cada lado para conocer la diferencia (DIF1, DIF2, DIF3) que hay entre ellos:

$$RES1 = LD(49) - LI(53) = DIF1$$

$$RES2 = LD(50) - LI(52) = DIF2$$

$$RES3 = LD(61) - LI(63) = DIF3$$

Obteniendo como resultados del ejemplo planteado anteriormente:

$$DIF1 = 0.001$$

$$DIF2 = 0.001$$

$$DIF3 = 0.001$$

4. *Definir niveles de asimetría*: Para cumplir con el objetivo de este trabajo se asignaron tres niveles de asimetría: casi nulo, moderado y severo.

Posteriormente luego de haber hecho las restas y tener las diferencias entre cada punto de cada lado, se promedian junto con los puntos del centro para después sacar el máximo y mínimo de los registros y así poder asignarle un rango a cada nivel de asimetría quedando establecidos en la Tabla 4 de la siguiente manera:

Tabla 4 Rangos de asimetría facial

Nivel de Asimetría	Desde	Hasta
Casi Nulo	0.0000846416	0.0001515233
Moderado	0.0001516233	0.0038525829
Severo	0.0046739103	0.0085488006

Se tuvieron 185 casos exitosos de personas sanas. De acuerdo con todo esto para poder entrenar la red se necesita generar una nueva base de datos que constara únicamente de 7 atributos y 3 clases (Ver Figura 20).

R1	R2	R3	R4	R5	R6	R7	CLASE
0.00115629	0.00110838	0.00095076	0.00094730	0.00034218	0.00030089	0.00080097	CASI NULO
0.00109237	0.00090766	0.00100489	0.00104536	0.00037129	0.00063439	0.00084266	CASI NULO
0.00015982	0.00034803	0.00000000	0.00000000	0.00000000	0.00000000	0.00175901	CASI NULO
0.00031658	0.00039061	0.00033296	0.00030617	0.00038779	0.00033560	0.00034495	CASI NULO
0.00043358	0.00029596	0.00000000	0.00000000	0.00058156	0.00052873	0.00030664	CASI NULO
0.00046252	0.00024973	0.00857386	0.00064559	0.00020060	0.00034557	0.00032374	MODERADO
0.00500803	0.00541596	0.00435988	0.00390509	0.00238487	0.00201195	0.00384763	MODERADO
0.00039583	0.00058496	0.00044934	0.00042410	0.00019610	0.00015310	0.00036724	MODERADO
0.00084206	0.00035633	0.00034742	0.00031677	0.00022375	0.00019179	0.00037969	MODERADO
0.00098962	0.00141904	0.00136570	0.00119613	0.00069776	0.00058809	0.00104272	MODERADO
0.00252851	0.00355054	0.00242463	0.00190266	0.01024522	0.01245319	0.00551746	SEVERO
0.00637433	0.00748566	0.00659287	0.00623367	0.01112344	0.01162311	0.00823885	SEVERO
0.00111756	0.00080453	0.00049953	0.00029236	0.01423411	0.01346553	0.00506894	SEVERO
0.00331036	0.00337659	0.00311562	0.00317879	0.00821732	0.01012341	0.00522035	SEVERO
0.00585955	0.00638957	0.00579941	0.00493518	0.00731350	0.00892121	0.00653640	SEVERO

Figura 20 Clases (casi nulo, severo, moderado) y Atributos (R1-R7)

Dónde los primeros tres atributos ($R1$, $R2$, $R3$) son los resultados de las tres restas que se mencionan en el paso número 3 de la optimización de los datos; los tres siguientes ($R4$, $R5$, $R6$) son los radianes de los ángulos del centro (puntos 51, 62, 66), esos se quedan intactos, ya que el definir a qué lado corresponden sea izquierdo o derecho es complejo de deducir. El último atributo ($R7$) corresponde a la suma de las diferencias más los centros, y la última columna (Clase) es el promedio de la suma de los siete atributos anteriores y corresponden a cada nivel de asimetría antes asignados.

3.8 Conclusiones del capítulo

En este capítulo se llevaron a cabo 4 pasos para poder realizar el entrenamiento de la red: primero se guardaron las coordenadas, es decir, después de que la aplicación que se

utilizó reconoce los puntos característicos de la cara, estos se dividieron en lado izquierdo y lado derecho. Posteriormente se realizó la conversión a radianes para trabajar con números más precisos. En tercer lugar, para medir el grado de asimetría que hay entre un lado y otro se hizo una resta que corresponde a cada punto. Por último se definieron los niveles de asimetría y se asignaron 3: casi nulo, severo y moderado.

CAPÍTULO 4 RESULTADOS

En el capítulo 4 se da a conocer el rendimiento y comportamiento de la red neuronal planteada, al comparar el desempeño con otros métodos clasificadores.

Inicialmente, se realizaron pruebas con datos de personas sanas, posteriormente, se trabajó con datos de niños con labio leporino.

Para ello, se muestran las tablas comparativas con los resultados alcanzados al trabajar con cada uno de los métodos clasificadores.

De esta manera se expone el rendimiento de la red propuesta.

En este capítulo se presentan los resultados que se obtuvieron al realizar el entrenamiento de la RNMPD y compararla con otros clasificadores. Para esta tarea fue necesario entrenar con una base de datos que consta de 8 atributos y 3 clases descritos en el capítulo anterior.

4.1 Resultados de la aplicación

Para llevar a cabo el entrenamiento y prueba de la red, primero se utilizó la aplicación mencionada en el capítulo 3. Dicha aplicación funciona de la siguiente manera:

1. Se abre la aplicación
2. Se selecciona una imagen de la galería.
3. La aplicación detecta los puntos de dicha imagen (Ver Figura 21).

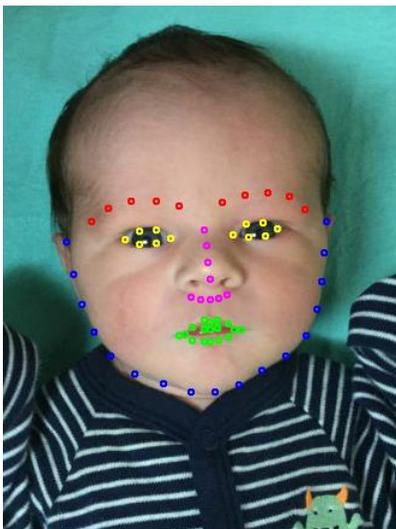
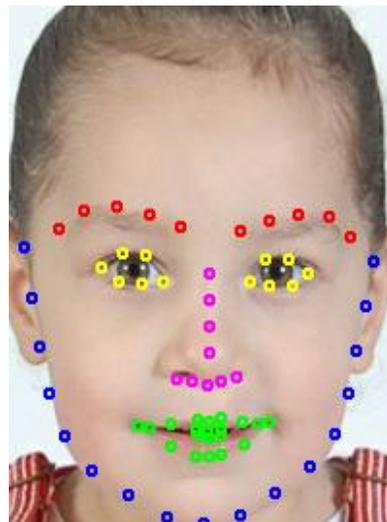
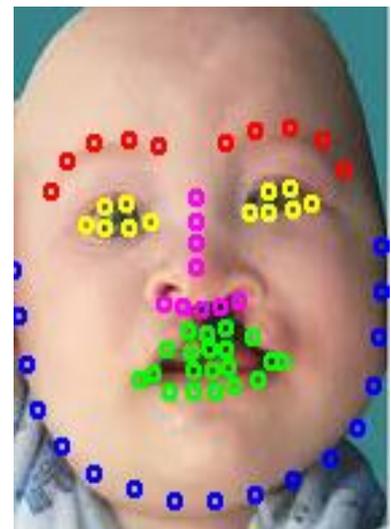


Figura 21 a) Detección de puntos en persona sin dismorfia



b) Detección de puntos en persona con operación



c) Detección de puntos en persona con dismorfia

4. Primero hace la obtención de coordenadas.
5. Obtiene el ángulo entre el eje central (lóbulo de nariz) hacia el punto a conocer (labio).
6. El ángulo es convertido a radianes y se almacenan registros con 10 posiciones decimales.
7. Se obtienen valores entre lado izquierdo y lado derecho para sus comparaciones.
8. Se realizan las restas acorde al mismo punto entra ambos lados.
9. Clasifica las imágenes en casi nulo, severo o moderado, según sea el caso

4.2 Características de los clasificadores utilizados en la investigación con Weka

Se llevó a cabo el entrenamiento y prueba de la RNMPD con la ayuda de un programa desarrollado en Visual studio. Se utilizó WEKA que tiene una colección de algoritmos de aprendizaje automático para tareas de minería de datos. Entre varias de sus herramientas se encuentra la clasificación de datos que fue lo que hizo posible llevar a cabo y analizar el entrenamiento y comportamiento de los 3 tipos de clasificadores con los que vamos a comparar la RNMPD:

1. *Perceptrón Multicapa (MLP)*: Es un clasificador que usa la retropropagación para clasificar instancias. Esta red se puede construir a mano, creada por un algoritmo o ambos. La red también puede ser monitoreada y modificada durante el tiempo de entrenamiento (ver Figura 22) [108].

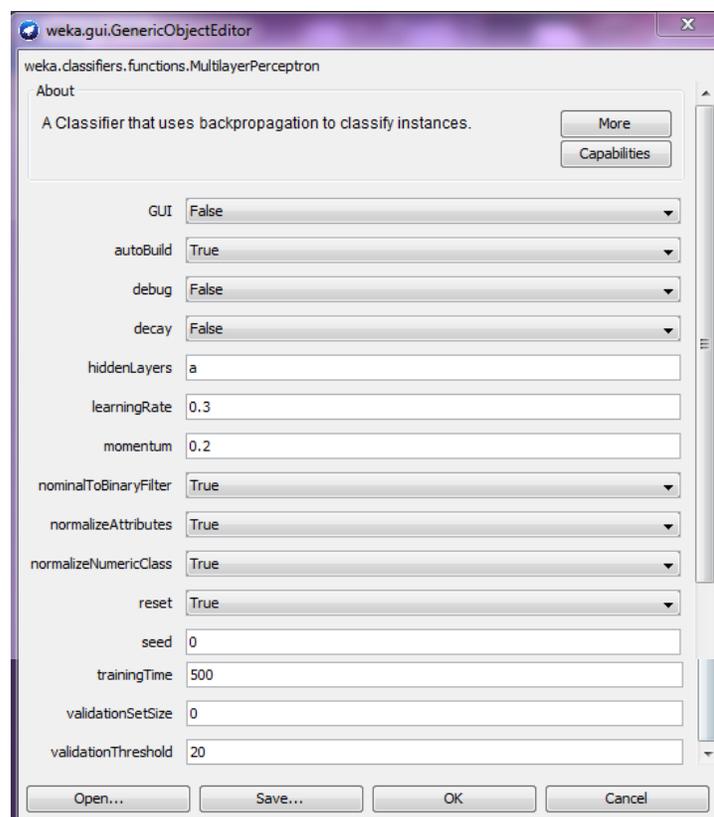


Figura 22 Interfaz de Multilayer Perceptron

- *Opciones GUI*: Esto permitirá la pausa y la alteración de la red neuronal durante el entrenamiento (Las alteraciones en la red neuronal solo se pueden realizar mientras la red no se está ejecutando).

- *AutoBuild*: Agrega y conecta capas ocultas en la red.
- *Depuración*: Si se establece en verdadero, el clasificador puede generar información adicional a la consola.
- *Decaimiento*: Esto hará que la tasa de aprendizaje disminuya. Esto puede ayudar a evitar que la red diverja de la producción objetivo, así como a mejorar el rendimiento general. Tenga en cuenta que la velocidad de aprendizaje en descomposición no se mostrará en la interfaz gráfica de usuario, solo la velocidad de aprendizaje original.
- *HiddenLayers*: Define las capas ocultas de la red neuronal. Esta es una lista de números enteros positivos. 1 por cada capa oculta, para no tener capas ocultas ponga un 0 aquí.
- *LearningRate*: Esto preprocesará las instancias con el filtro. Esto podría ayudar a mejorar el rendimiento si hay atributos nominales en los datos.
- *NormalizeAttributes*: Normalizará los atributos. Esto podría ayudar a mejorar el rendimiento de la red. Esto no depende de que la clase sea numérica.
- *NormalizeNumericClass*. normalizará la clase si es numérica. Esto podría ayudar a mejorar el rendimiento de la red, normaliza la clase entre -1 y 1.
- *Reinicio*: Permitirá que la red se restablezca con una tasa de aprendizaje más baja. Si la red difiere de la respuesta, esto reiniciará automáticamente la red con una tasa de aprendizaje más baja y comenzará a entrenar nuevamente. Esta opción solo está disponible si la GUI no está configurada.
- *Semilla*: Utilizada para inicializar el generador de números aleatorios. Los números aleatorios se usan para establecer los pesos iniciales de las conexiones entre los nodos, y también para mezclar los datos de entrenamiento.
- *TrainingTime*: El número de épocas a las que entrenar. Si el conjunto de validación no es cero, entonces puede terminar la red anticipadamente
- *ValidationSetSize*: El tamaño porcentual del conjunto de validación. (El entrenamiento continuará hasta que se observe que el error en el conjunto de validación ha empeorado constantemente o si se ha alcanzado el tiempo de entrenamiento).

- *ValidationThreshold*: se utiliza para finalizar la prueba de validación. El valor aquí indica cuántas veces seguidas el error del conjunto de validación puede empeorar antes de que finalice el entrenamiento.

2. *Algoritmo del vecino más cercano (IBK)*. Es el clasificador de vecinos más cercanos. Puede seleccionar el valor apropiado de k basado en la validación cruzada. También puede hacer ponderación de distancia. (Ver Figura 23) [109].

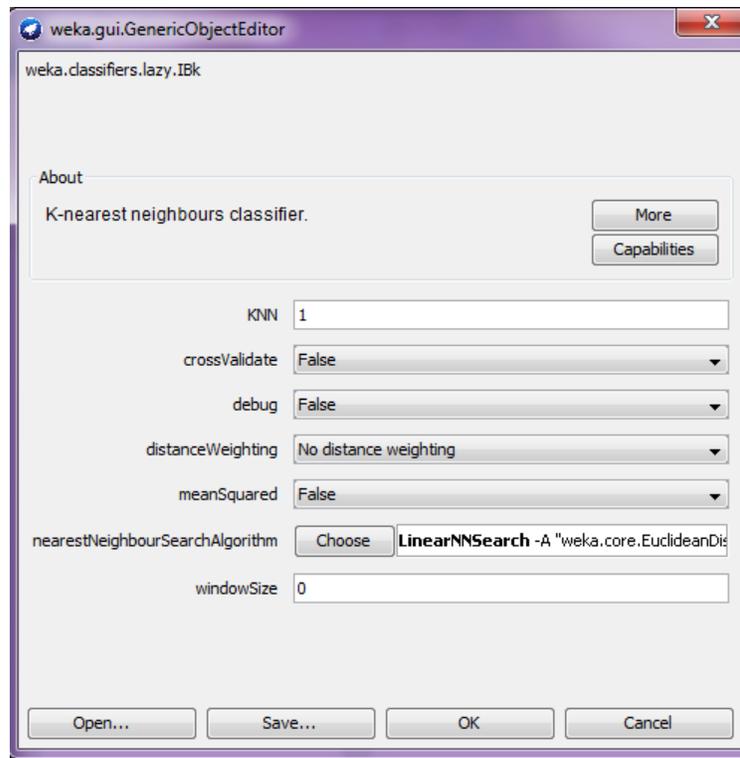


Figura 23 Interfaz Gráfica de IBK

- *KNN*: La cantidad de vecinos a usar.
- *CrossValidate*: Si se usará la validación cruzada de hold-one-out para seleccionar el mejor valor de k .
- *Depuración*: si se establece en verdadero, el clasificador puede generar información adicional a la consola.
- *DistanceWeighting*: Obtiene el método de ponderación de distancia utilizado.
- *NeanSquared*: si se usa el error cuadrático medio en lugar de error absoluto medio cuando se realiza la validación cruzada para problemas de regresión.

- *NearesNeighbourSearchAlgorithm*: El algoritmo de búsqueda de vecinos más cercano a usar
 - *WindowSize*: Obtiene la cantidad máxima de instancias permitidas en el grupo de entrenamiento. La adición de instancias nuevas por encima de este valor dará como resultado la eliminación de instancias antiguas. Un valor de 0 significa que no hay límite para la cantidad de instancias de entrenamiento.
3. *Mapa de autoorganización (SMO)*. Implementa el algoritmo de optimización secuencial mínimo de John Platt para entrenar un clasificador de vectores de soporte. Esta implementación reemplaza globalmente todos los valores perdidos y transforma los atributos nominales en binarios. También normaliza todos los atributos por defecto. Para obtener estimaciones de probabilidad adecuadas, utilice la opción que se ajusta a los modelos de regresión logística a las salidas de la máquina de vectores de soporte (Ver Figura 24) [110].

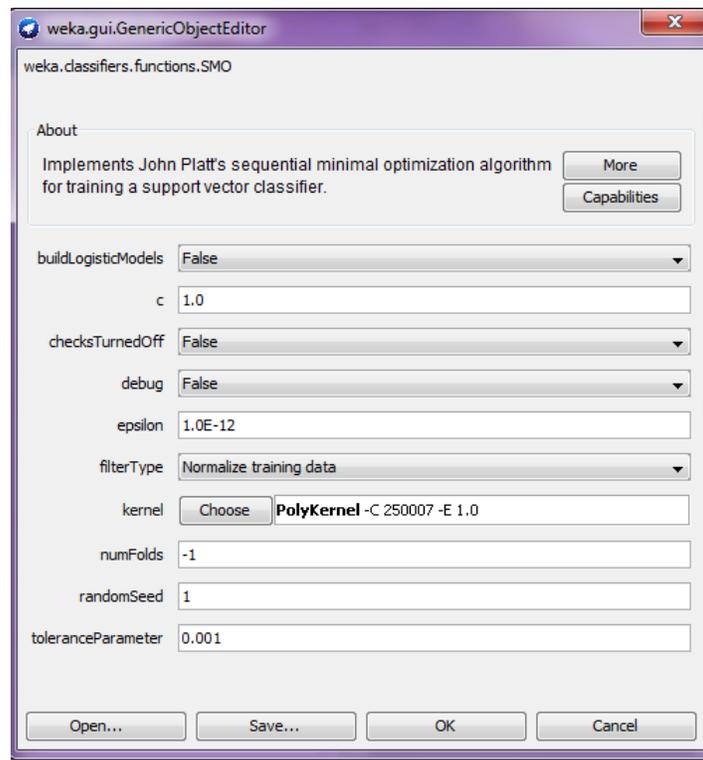


Figura 24 Interfaz Gráfica de SMO

- *BuildLogisticModels*: para las estimaciones de probabilidad adecuadas.
- *C*: El parámetro de complejidad C.
- *ChecksTurnedOff*: Desactiva los chequeos que consumen tiempo.

- *Depuración*: si se establece en verdadero, el clasificador puede generar información adicional a la consola.
- *Epsilon*: Para el error de redondeo (no debe ser cambiado).
- *FilterType*: Determina cómo los datos serán transformados.
- *Kernel*: El kernel a usar.
- *NumFolds*: el número de pliegues para la validación cruzada utilizada para generar datos de entrenamiento para modelos logísticos
- *RandomSeed*: semilla de número aleatorio para la validación cruzada.
- *ToleranceParameter*: El parámetro de tolerancia (no debe cambiarse).

4.3 Rendimiento de la propuesta con otros métodos clasificadores

Se entrenó y probó con cuatro diferentes escenarios; de los datos obtenidos se promedió el porcentaje de error y el porcentaje de datos correctos para posteriormente compararlos. De acuerdo a esta comparación se tiene que la red IBK es la que tiene un porcentaje de error más alto (9.06%), sin embargo, no es mucha la diferencia comparada con Multilayer Perceptron y SMO (menos de 1% de diferencia), ya que ambas tienen 8.18% de error y 91.82% de datos correctos.

En el caso de la RMPD solo hay un 7.81% de error, lo que significa que es la que trabaja de una manera más certera (Ver Tabla 5).

Tabla 5 Comparación de las diferentes RNA

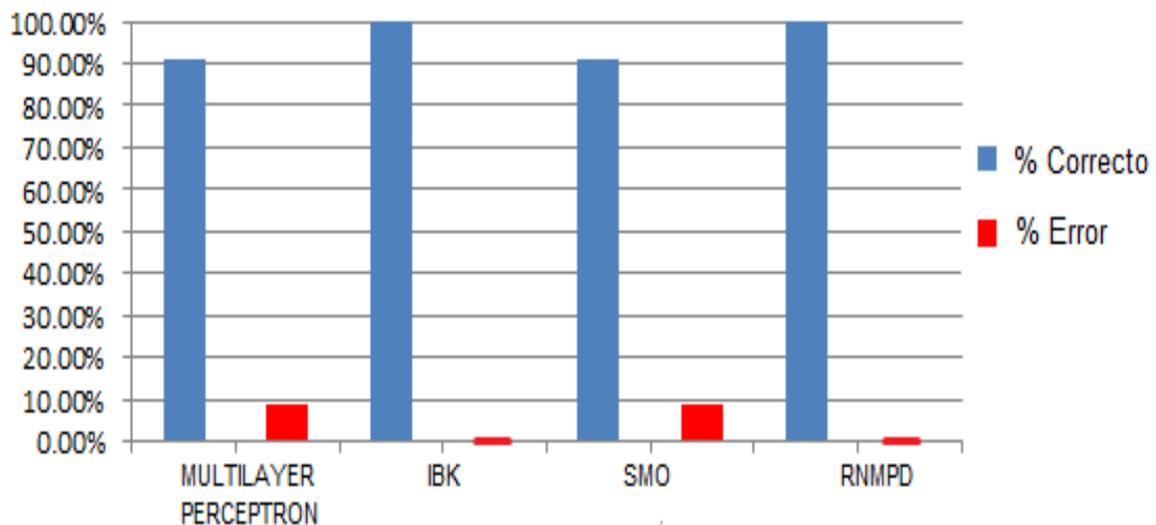
Instancias		Multilayer Perceptron		IBK		SMO		RNMPD	
Entrena	Prueba	%error	%Correcto	%error	%Correcto	%error	%Correcto	%error	%Correcto
78	78	8.97%	91.03%	0%	100%	8.97%	91.03%	0.00%	100.00%
78	160	8.75%	91.25%	5%	95%	8.75%	91.25%	3.75%	96.25%
78	80	7.50%	92.50%	15%	85%	7.50%	92.50%	11.25%	88.75%
160	80	7.50%	92.50%	16.25%	83.75%	7.50%	92.50%	16.25%	83.75%
Promedio		8.18%	91.82%	9.06%	90.94%	8.18%	91.82%	7.81%	92.19%

En las primeras dos columnas se encuentran el número de instancias con las que se llevó a cabo el entrenamiento y prueba de cada clasificador, en las siguientes columnas se muestra tanto el nombre de la red o clasificador, así como los resultados obtenidos y la

última fila de cada columna representa el promedio total del desempeño que mostro cada red o clasificador.

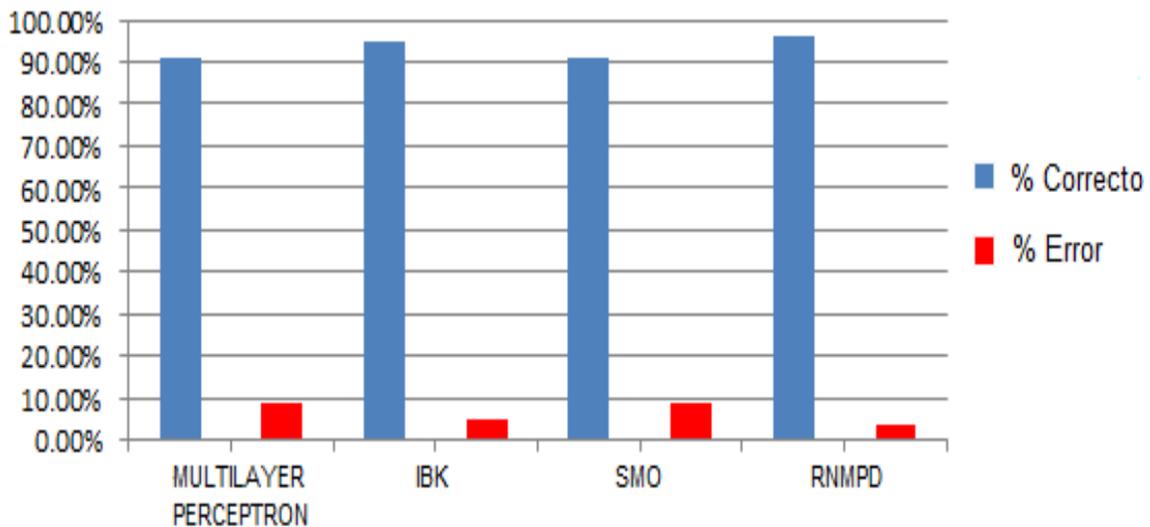
Todos los registros con los que se trabajó son casos que incluyen los tres niveles de asimetría mencionados en el capítulo 3. La información recabada se ilustra gráficamente de forma generalizada para observar los datos y proporciones que se obtuvieron como resultado después del análisis y la comparación de los mismos a lo largo de este estudio.

En el primer escenario se entrenó con una cantidad de 78 registros y se probó con esos mismos 78. Se esperaba que al entrenar y probar con los mismos datos y la misma cantidad de registros todas las redes reflejaran con un 100% de porcentaje correcto de clasificación, pero al observar la Gráfica 1 podemos notar que solo 2 de ellas (IBK y RNMPD) obtuvieron el 100%, mientras que Multilayer perceptron y SMO arrojaron solo el 91.03% cada una.



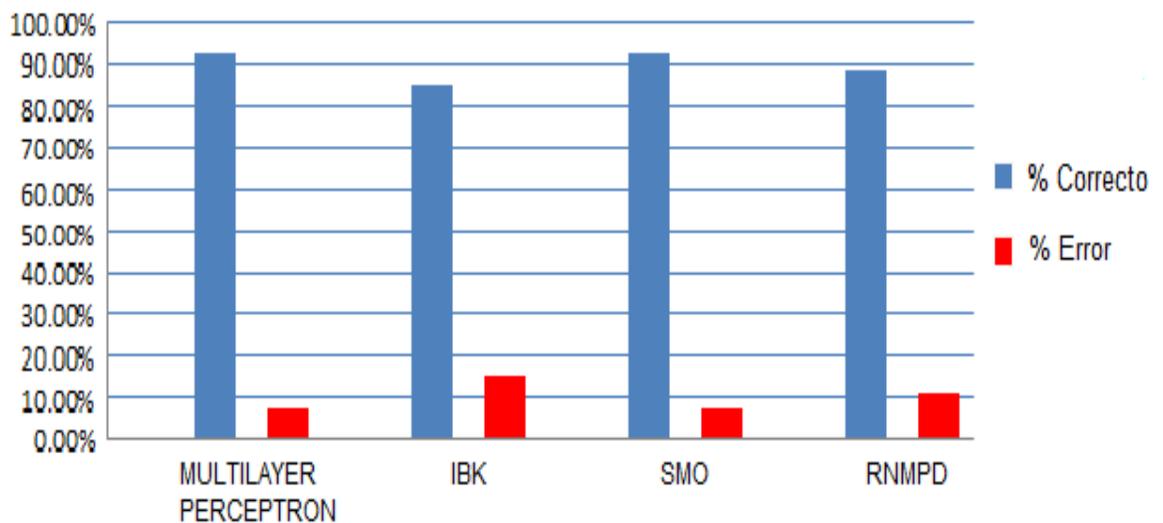
Gráfica 1 Primer escenario con 78 datos de prueba y 78 datos de entrenamiento

El segundo escenario se entrenó con los 78 registros del escenario anterior, pero se probó con una cantidad de 160 conformada por los mismos 78 más 82 registros desconocidos y los resultados que se obtuvieron establecieron que el comportamiento de la RNMPD tuvo una mejora frente a las demás redes tal como se muestra en la gráfica (Ver Gráfica 2).



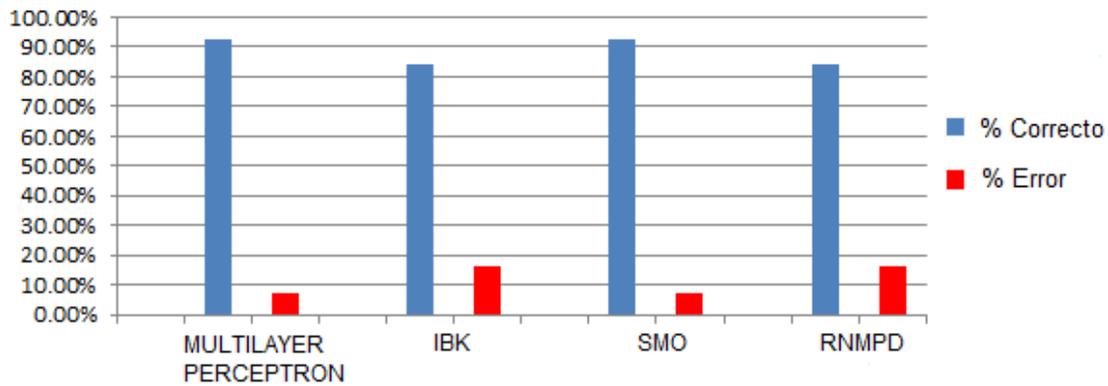
Gráfica 2 Segundo escenario 160 datos de prueba y 78 datos de entrenamiento

En el tercer escenario se entrenó una vez más con los 78 registros y se probó con 80 pero esta vez todos fueron datos desconocidos, es decir, se probó con datos que la red no conocía en su entrenamiento y los resultados mostraron un cambio nuevamente (Ver Gráfica 3).



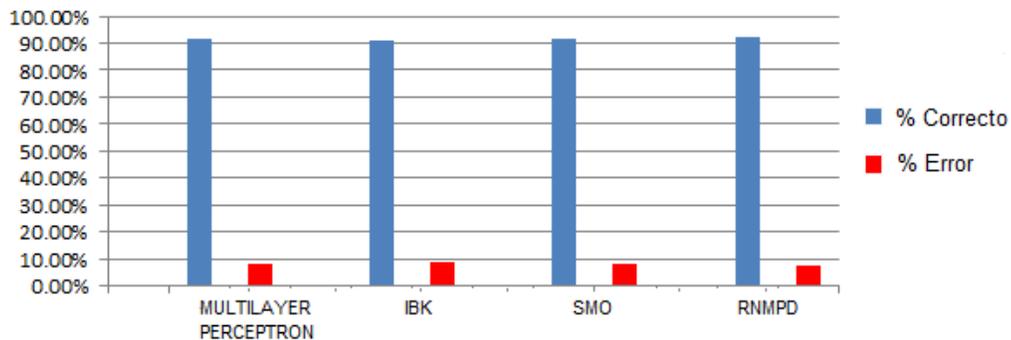
Gráfica 3 Tercer escenario 80 datos de prueba y 78 datos de entrenamiento

En el cuarto y último escenario se entrenó con 160 registros y se probó con los 80 registros desconocidos. Los resultados fueron más bajos en este escenario comparado con los otros tres (Ver Gráfica 4).



Gráfica 4 Cuarto escenario 80 datos de prueba y 160 datos de entrenamiento

Finalmente, se obtuvo el promedio de los cuatro escenarios de cada una de las redes o clasificadores teniendo los siguientes resultados; *Multilayer Perceptron* obtuvo un 91.82% de porcentaje correcto al igual que *SMO*, el clasificador *IBK* obtuvo un 90.94% correcto y la *RNMPD* logro un 92.19% de porcentaje correcto, alcanzando este último un mejor desempeño (Ver Gráfica 5).



Gráfica 5 Promedio total de los escenarios

4.4 Conclusiones del capítulo

En este capítulo se presentó el desempeño de diferentes RNA para conocer el rendimiento y el nivel de convergencia en un número finito de pasos de cada uno de los métodos clasificadores, ante la recuperación de patrones de puntos estratégicos faciales. Así mismo se pudo realizar la comparación de diferentes técnicas y conocer el desempeño de cada una. Cabe mencionar que los datos obtenidos para realizar los experimentos fueron obtenidos de imágenes reales, es decir, se tomaron fotos de personas con y sin Síndrome

Pediátrico Dismorfogénico facial (labio leporino). Los datos están representados por 3 Clases (casi nulo, severo y moderado) y 7 atributos (los primeros tres atributos son los resultados de las tres restas que se mencionaron en el tercer subtema del capítulo 3; los tres siguientes son los radianes de los ángulos del centro y el último atributo corresponde a la suma de las diferencias más los centros).

Los resultados obtenidos permitieron realizar una comparación y comprobar la eficiencia de cada una de las RNA, teniendo como resultado que el mayor porcentaje de efectividad fue el de la RNMPD.

CAPÍTULO 5 CONCLUSIONES Y TRABAJOS A FUTURO

La última sección del presente trabajo tiene dos partes: la primera corresponde a las conclusiones generales que se obtuvieron del entrenamiento de la RNMPD, de esta manera se refleja el logro de los objetivos planteados en esta tesis.

En segundo lugar, se menciona una serie de recomendaciones para dar pauta a que los futuros investigadores sigan desarrollando proyectos siguiendo esta línea de investigación.

5.1 Conclusiones

La biometría y el reconocimiento facial (capítulo 2) cada día cobran un mayor auge derivado principalmente a las nuevas aplicaciones que lo incluyen. Sebastián Bronte Palacios habla en su artículo “Sistema de Detección y Reconocimiento Facial de Conductores Mediante Sistemas de Visión Computacional” que la biometría se basa en calcular distancias entre partes significativas de la cara, como pueden ser la distancia entre ojos, dimensiones de la nariz, tamaño de la boca, etc [111].

Este cálculo de distancias puede fallar si las cámaras están mal enfocadas o si el objetivo se mueve mucho obteniendo unas imágenes borrosas. Otras posibles variaciones que nos podemos encontrar a la hora de medir distancias en una cara son los gestos, o dismorfias faciales (labio leporino) con los cuales se puede modificar sustancialmente las dimensiones de la boca y de los ojos. Si queremos unas buenas medidas de distancia entre puntos característicos de la cara [112].

Las redes neuronales son una teoría relativamente nueva que junto a otras técnicas de inteligencia artificial han generado soluciones muy confiables para este y otros problemas de ingeniería. Los cuales a pesar de poder ser solucionados por métodos tradicionales, encuentran en las redes neuronales una alternativa fácil de implementar y altamente segura. Al escoger las redes neuronales como método de solución a un problema en particular, es necesario tener un entendimiento profundo y completo de lo que es el problema, pues ello facilita la elección de los patrones de entrenamiento y ofrece una idea general de la arquitectura que debe tener la red.

En la presente tesis se realizó el entrenamiento de una Red Neuronal Morfológica con Procesamiento en sus Dendritas para la clasificación de asimetría facial en personas con labio leporino.

Dichas redes utilizan máximos o mínimos de sumas para llevar a cabo sus operaciones, a diferencia de la mayoría de las redes neuronales, las cuales basan su funcionamiento en sumas de productos.

De acuerdo a lo estudiado en el estado del arte en el capítulo 1, se decidió trabajar con el algoritmo de la RNMPD de Elizabeth Guevara y Humberto Sossa [6] que funciona de acuerdo a los siguientes cuatro pasos: consta de 4 pasos:

1. Seleccionar los patrones de todas las clases y abrir un hiper-cubo con un tamaño tal que todos los elementos de las clases queden dentro del hiper-cubo. El hiper-cubo debe tener un margen de cada lado, para tener una mejor tolerancia al ruido al momento de clasificar.

2. Dividir el hiper-cubo en 2 hiper-cubos más pequeños y verificar si se satisface el criterio de paro. El cual implica, que cada hiper-cubo encierre patrones que pertenezcan a una misma clase. Si es el caso, etiquetar el hiper-cubo con el nombre de la clase correspondiente y parar el proceso de aprendizaje, seguir con el paso 4.

3. El paso 3 consta de dos etapas:

- Si al menos uno de los hiper-cubos generados tiene patrones de más de una clase, dividir el hiper-cubo en 2 hiper-cubos más pequeños. Repetir de manera iterativa el proceso de verificación dentro de cada nuevo hiper-cubo generado, hasta que el criterio de paro se satisfaga.
- Una vez que todos los hiper-cubos fueron generados, si dos o más hiper-cubos de la misma clase comparten un lado en común serán agrupados dentro de una misma región. En la Figura 13 se muestra cómo es que se aplica este proceso de simplificación, el cual provoca que el número de hiper-cubos se reduzca.

4. Con base en las coordenadas de cada eje, calcular los pesos para cada hiper-cubo que encierra los patrones pertenecientes de la clase.

Una vez hecho lo anterior, se procede a entrenar la RNMPD. Para llevar a cabo dicho entrenamiento, primero fue necesario analizar e interpretar los diferentes Síndromes Pediátricos de Distrofia Facial, en segunda instancia se accedió a una base de datos con casos de personas con y sin dismorfia.

Para poder llevar a cabo el entrenamiento de la Red Neuronal, es importante contar con una base de datos con casos de personas con y sin dismorfia.

Previo a esto, fue necesario apoyarse de una aplicación de reconocimiento facial: “*Queiloquisis: Detección y Análisis facial*” [39] , que fue diseñada para dispositivos Android. La app está basada en la librería *DLIB*, ésta librería contiene algoritmos de aprendizaje de máquina y herramientas para crear software complejo que permite resolver diversos problemas del mundo real, por ello se utiliza en una amplia gama de dominios, incluyendo la robótica, dispositivos integrados, teléfonos móviles y grandes entornos de computación de alto rendimiento. Las licencias de *DLIB* son de código abierto, es decir, está permitido su uso en cualquier aplicación, de forma gratuita.

El motivo por el que se escogió esta aplicación es porque actualmente en el mercado, no se encuentran aplicaciones tecnológicas móviles que se especialicen en este campo (dismorfias faciales), es porque la mayoría utilizan la librería de *OpenCV*, que aunque es buena, identifica una menor cantidad de puntos que la librería *DLIB*. Identifica 68 puntos, y funciona de la siguiente manera:

1. Primero hace la obtención de coordenadas.
2. Convierte coordenada rectangular a coordenada polar (con la función *atan2* en java).
3. Obtiene el ángulo entre el eje central (lóbulo de nariz) hacia el punto a conocer (labio).
4. El ángulo es convertido a radianes y se almacenan registros con 10 posiciones decimales.
5. Se obtienen valores entre lado izquierdo y lado derecho para sus comparaciones.
6. Se realizan las restas acorde al mismo punto entra ambos lados.
7. Se promedian las diferencias y así, se obtiene un valor único para cada registro.
8. Se hicieron 185 pruebas para así, catalogar el nivel de asimetría.

Posteriormente con los datos que se obtuvieron de la aplicación, se entrenó y probó la *RNMPD* creada en *Visual Studio*, para conocer su comportamiento ante el Síndrome Pediátrico de Distrofia Facial para finalmente hacer una comparación de dicha red con otros métodos clasificadores (*Multilayer Perceptrón*, *IBK* y *SMO*).

Se realizó el entrenamiento y prueba con cuatro diferentes escenarios; de los datos obtenidos se promedió el porcentaje de error y el porcentaje de datos correctos para posteriormente compararlos. De acuerdo a esta comparación se tiene que la red *IBK* es la que tiene un porcentaje de error más alto (9.06%), sin embargo, no es mucha la diferencia

comparada con Multilayer Perceptron y SMO (menos de 1% de diferencia), ya que ambas tienen 8.18% de error y 91.82% de datos correctos. En el caso de la RNMPD solo hay un 7.81% de error, lo que significa que la RNMPD trabaja mejor que otros métodos clasificadores.

5.2 Trabajos a futuro

Con lo concluido en el tema 5.1 se puede ver que la eficiencia del trabajo, acorde con lo obtenido de la aplicación móvil y la RNMPD, es útil. Y el proceso conlleva a futuros análisis para el sector salud, ya que está enfocado principalmente para beneficio de doctores y especialistas de diversas áreas como dermatología, cirugía maxilofacial y cirugía plástica [113].

Debido a que en la literatura no se han encontrado investigaciones que hayan utilizado las Redes Neuronales Artificiales para imágenes de personas con Dismorfia Facial; este proyecto servirá para abordar esta necesidad clínica, y así recolectar y organizar los datos de rasgos físicos faciales característicos del tipo de Distrofia Facial (Ectodermica-Fisura palatina, Ectrodactilia-Displasia o Acro-Osteólitica), a través del entrenamiento de una RNMPD [114].

Con este trabajo se desea destacar el comportamiento de la RNMPD ante problemas (dismorfia facial) del área de medicina (psicología psiquiatría y cirugías) y coadyuvar al área de informática o sistemas computacionales en el desarrollo de un algoritmo eficiente utilizando este tipo de red para la implementación de una aplicación móvil que permita identificar el tipo de dismorfia. Este proyecto fue enfocado en personas con labio leporino pero también podría ser aplicado en otros tipos de dismorfias o síndromes [115]:

1. Síndrome de alcoholismo fetal
2. Síndrome de Bell
3. Síndrome de Down
4. Síndrome de Apert

Con la finalidad de que cirujanos plásticos o maxilofaciales puedan clasificar el nivel de asimetría de sus pacientes antes de una intervención quirúrgica y después de la misma, esto con la finalidad de saber que tanto fue lo que mejoró el aspecto del paciente y si necesita otra intervención.

Bibliografía

- [1] E. J. ROLDAN, Síndromes Pediátricos Dismorfogénicos, Capitel, 1980.
- [2] M. Kaser-Kupfer, Ectrodactyly, ectodermal dysplasia and cleft syndrome, 1973.
- [3] R. Gerard, «Ectrodactyly, ectodermal dysplasia, and cleft lip-palate syndrome,» 1973.
- [4] E. Navarrete Hernández, S. Canún Serrano y M. d. C. Sierra Romero, «Prevalencia de malformaciones congénitas registradas en el certificado de nacimiento y de muerte fetal,» Mexico, 2013.
- [5] D. Alvarez , W. Castrillon y L. Andrés, «Técnicas de extracción de características en imágenes para el reconocimiento de expresiones faciales,» *Scientia et Technica*, n° 38, pp. 7-12, 2008.
- [6] C. Bishop, Neural Network for Pattern Recognition, Firts ed., New York: Oxford University Press, 2008..
- [7] H. Sossa y E. Guevara, «Modified dendrite morphological neural network applied to 3D object recognition,» *Lecture Notes in Computer Science, Springer*, vol. 7914, pp. 314-324, 2013.
- [8] P. García, «Reconocimiento de imágenes utilizando redes neuronales artificiales,» Universidad Complutense de Madrid , Madrid, 2013.
- [9] M. A. V. Lopez, «Sistema de reconocimiento facial mediante tecnicas de vision tridimensional.» [En línea]. [Último acceso: 2017].
- [10] M. Merida, *Reconocimiento Biométrico Basado en Imágenes de Huellas Palmares*, 2012..
- [11] G. Sanz y J. M. de la Cruz, *Visión por computadora Imágenes digitales y aplicaciones*, Segunda ed., Alfaomega, 2008..
- [12] L. Yang y G. Li, «TCM-KNN Scheme for Network Anomaly Detection Using Feature-Based Optimizations,» *ACM*, pp. 2013-2109, March 2008..
- [13] J. F. Serrano, *Recuperación de imágenes mediante rasgos descriptores globales y locales*, 2011..
- [14] H. Mejia Cabrera, L. Vives Garnique y W. H. Cruz Cabrera, «Sistema Inteligente de Diagnostico Médico de Infecciones Respiratorias Agudas de Niños Menores de 5 años,» *TZHOECOEN*, vol. 5, n° 2, pp. 109-126, Junio 2013..
- [15] R. Rodríguez y H. Sossa, *Procesamiento y análisis digital de imágenes*, Primera ed., México: Alfaomega, 2012..
- [16] M. Bernes, « Genes, Brain and Devlopment: The Neurocognition of genetic Disorders,» Cambridge University Press., 2010.

- [17] S. Skallerup, «Bebés con síndrome de Down: Nueva Guía Para Padres.,» Bethesda, 2009.
- [18] M. Sierra, E. Navarrete, S. Canun, A. Reyes y J. Valdes, «Prevalencia del síndrome de Down en México utilizando los certificados de nacimiento vivo y de muerte fetal durante el periodo 2008-2011,» 2014.
- [19] J. Camargo, E. Perez, S. M y R. Gutierrez, «Algoritmo para la obtención de parámetros antropométricos en imágenes de rostros frontales.,» 2011.
- [20] I. Ahamed, R. Nagendra y P. S. Sastry, «A Neural Network Based Automatic Generation Controller Design through Reinforcement Learning,» *International Journal of Emerging Electric Power Systems Reinforcement Learning*, vol. 6, n° 1, pp. 1-16, 2006..
- [21] I. Del Campo, R. Finker, J. Echanobe y K. Basterretxea, «Controlled accuracy approximation of sigmoid function for efficient FPGA-based implementation of artificial neurons,» *Electronics Letters*, vol. 49, n° 25, pp. 1598-1600, December 2013..
- [22] B. Fröhlich y et al., «Large-scale gaussian process multi-class classification for semantic segmentation and facade recognition,» *Machine Vision and Applications, Springer*, vol. 24, pp. 1043-1053, 2013..
- [23] X. Parra y A. Català, «Qualitative Radial Basis Function Networks Based on Distance Discretization for Classification Problems,» *Artificial Neural Networks – ICANN 2007 Springer*, vol. 4668, pp. 520-528, 2007..
- [24] S. A. Pérez, *Modelado y Control de Sistemas Híbridos con Redes de Petri Difusas y Redes Neuronales*, 2002..
- [25] G. X. Ritter y P. Sussner, «Morphological perceptrons,» *Intelligent Systems and Semiotics*, pp. 221-226, 1997..
- [26] . K. Bache y M. Lichman, University of California, School of Information and Computer Science, 2013.. [En línea]. Available: <http://archive.ics.uci.edu/ml>.
- [27] M. E. G. Chang, «Diseño e implementación de una herramienta de detección facial,» 2009. [En línea]. [Último acceso: Febrero 2017].
- [28] D. Romero, A. Frizera y T. Freire, «Reconocimiento en-línea de acciones humanas basado en patrones de RWE aplicado en ventanas dinámicas de momentos invariantes,» *Revista Iberoamericana de Automática e Informática industrial*, vol. 11, n° 2, pp. 202-211, 2014..
- [29] G. X. Ritter, L. Iancu y G. Urcid, «Morphological perceptron with dendritic structure,» *the 12th IEEE international Conference*, vol. 2, pp. 1296-1301, 2003..
- [30] L. Blasquez, «Reconocimiento facial basado en puntos característicos de la cara en entornos no controlados,» 2013.
- [31] A. Morelli y S. Padovani, «Detección y reconocimiento de caras,» Universidad de Buenos Aires., 2011.

- [32] M. Peña, «Un Proceso de Aprendizaje para Reconocimiento de Objetos en Línea en Tareas Robotizadas,» Universidad Nacional Autonoma de México, 2013.
- [33] Mendez y Caro-Contreras, «Retículas de Conceptos utilizando una RNMPD,» 2013.
- [34] E. Guevara, «Método para el entrenamiento de neuronas morfológicas con procesamiento dendral,» Instituto Politecnico Nacional, 2016.
- [35] M. Sarango y M. Mainato, «Análisis comparativo de técnicas de reconocimiento de rostros basado en modelos y en imagen usando un módulo de inteligencia artificial en MATLAB,» 2014.
- [36] T. Guerrero, «presentó la implementación de una red neuronal morfológica con procesamiento dendral en un FPGA,» 2015.
- [37] T. Jarkko, «Simultaneous input variable and basis function selection for RBF networks,» *Elsevier*, vol. 72, pp. 2649-2658, 2009..
- [38] M. Paz, B. Grosiman, R. Flores, M. Ormazabal y P. Barbero, «Guía para la detección y descripción de anomalías congénitas.,» 2014.
- [39] J. Guzman, Queiloquisis, Mexico, 2017.
- [40] M. P. Bidondo, B. Groisman, R. Flores, M. Ormazabal y P. Barbero, «Guía para la detección y descripción de anomalías congenitas,» Atlas RENAC, Argentina.
- [41] B. Leibe y B. Schiele, «Analyzing appearance and contour based methods for object categorization",» *IEEE Conference on Computer Vision and Pattern Recognition*, vol. 2, pp. 409-415, 2003.
- [42] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann y I. H. Witten, «The WEKA Data Mining Software: An Update,» *SIGKDD Explorations*, vol. 11, 2009.
- [43] R. Gonzalez y R. Woods, Digital Image Processing, Pearson, 2007.
- [44] F. Rosenblatt, «The perceptron: A probabilistic model for information storage and organization in the brain,» *Psychological Review*, vol. 65, pp. 386-408, 1958.
- [45] J. J. Hopfield, «Neural Networks and physical systems with emergent collective computational abilities,» *Proceedings of the National Academy of sciences of the USA*, vol. 79, pp. 2554-2558, 1982.
- [46] Z. Aihua , C. Chen y R. K. Hamid, «A New Adaptive LSSVR with Online Multikernel RBF Tuning to Evaluate Analog Circuit Performance,» *Hindawi Publishing Corporation*, 2013..
- [47] T. Amaral, S. McKenna y et al., «Classification and Immunohistochemical Scoring of Breast Tissue Microarray Spots,» *IEEE Transaction on Biomedical Engineering*, vol. 60, nº 10, pp. 2806-2814, October 2013..
- [48] R. A. Araujo, F. Madeiro, R. de Sousa y F. Pessoa, «Modular Morphological Neural Network Training

via Adaptive Genetic Algorithm For Designing Translation Invariant Operators,» *IEEE*, vol. 2, 2006..

- [49] T. Bacek, D. Majetic y et al., «Analysis of Iterative Learning Algorithms for the Multilayer Perceptron Neural Network,» *Annals of DAAAM*, vol. 22, n° 1, pp. 1133-1135, 2011..
- [50] J. Bojorquez, *Uso de redes neuronales artificiales para estimar la respuesta sísmica de sistemas estructurales*, 2011..
- [51] M. Brizzotti y A. de Carvalho, «Comparing Different Clustering Techniques RBF Network Training,» *IEEE Sixth Brazilian Symposium in Neural Networks*, pp. 225-230, 2000..
- [52] J. Bustamante, «Redes neuronales: aplicación de una herramienta computacional en Cardiología clínica,» *Elsevier Doyma Revista Colombiana de Cardiología*, vol. 21, n° 4, pp. 224-225, 2014..
- [53] J. Cevallos A., «Redes Neuronales de Base Radial aplicadas a la mejora de la calidad,» *Redalyc.org*, vol. 11, n° 2, pp. 63-72, Julio 2008..
- [54] J. Chahuara, 2005.. [En línea]. Available:
http://sisbib.unmsm.edu.pe/bibvirtualdata/tesis/ingenie/chahuara_qj/Cap2.pdf.
- [55] B. Chiang Ng., Z. M. Darus y et al., «Application of Multilayer Perceptron and Radial Basis Function Neural Network in Steady State Modeling of Automotive Air Conditioning System,» *IEEE International Conference on Control System, Computing and Engineering*, vol. 978, n° 1, pp. 617-622, 2012..
- [56] L. Chien-Cheng, C. Pau-Choo y et al., «Robust Radial Basis Function Neural Networks,» *IEEE Transactions on System*, pp. 674-685, 1999..
- [57] P. Chudzian, «Radial Basis Function Kernel Optimization for Pattern Classification,» *Computer Recognition Systems 4, Springer*, vol. 95, pp. 99-108, 2011..
- [58] O. De Souza, P. C. Cortez y F. A.T.F. da Silva, *Grayscale images and RGB video: compression by morphological neural network*, Springer-Verlag, Heidelberg, 2012., pp. 213-224.
- [59] A. Delgado, «Aplicaciones de la Redes Neuronales en Medicina,» *Universidad Nacional de Colombia Revista de la Facultad de Medicina*, vol. 47, n° 4, pp. 221-223, 1999..
- [60] F. Fernández, C. Hervás y et al., «MELM-GRBF: A modified version of the extreme learning machine for generalized radial basis function neural networks,» *ELSEVIER*, vol. 74, n° 16, pp. 2502-2510, 2011..
- [61] F. J. Gallegos y et al., «Función de base radial de rango tipo M para la clasificación de imágenes de mamografía,» *Científica*, vol. 12, n° 2, pp. 55-65, 2008..
- [62] B. H., C. M. y et al., «Face recognition based on perceived facial images and multilayer perceptron neural network using constructive training algorithm,» *IET Computer Vision*, vol. 8, n° 6, pp. 729-739, May 2014..

- [63] Q. Ha y et al., «Enhanced radial basis function neural networks for ozone level estimation,» *Neurocomputing Elsevier*, pp. 1-9, December 2014.
- [64] M. Hafner, A. Gangl y et al., «Combining Gaussian Markov random fields with the discrete-wavelet transform for endoscopic image classification,» *IEEE*, pp. 1-6, July 2009..
- [65] K. Ichikawa y S. Morishita, «A Simple but Powerful Heuristic Method for Accelerating k-means Clustering of Large-Scale Data in Life Science,» *IEEE Xplore*, vol. 11, n° 4, pp. 681-391, August 2014..
- [66] A. F. J. L. J. D. S. G. L. S. F. H. J. Alcalá-Fdez, «KEEL Data-Mining Software Tool: Data Set Repository, Integration of Algorithms and Experimental Analysis Framework.,» *Journal of Multiple-Valued Logic and Soft Computing*, Vols. %1 de %217:2-3, pp. 255-287, 2011..
- [67] D. James, S. Scott, W. O'Hare, Z. Ali y F. J. Rowell, «Classification of fresh edible oils using a coated piezoelectric sensor array-based electronic nose with soft computing approach for pattern recognition,» *Transactions of the Institute of Measurement and Control*, vol. 26, n° 1, pp. 3-18, 2004..
- [68] H. Jinbin y D. Wei, «A Robust Morphological Associative Memory Endowed with Dendrites,» *IEEE, Neural Networks and Brain*, vol. 1, pp. 147-149, 2005..
- [69] Z. Jingbo, B. Thörnberg y et al., «Color Segmentation on FPGA Using Minimum Distance Classifier for Automatic Road Sign Detection,» *IEEE*, vol. 978, n° 1, 2012..
- [70] T. Jinlan, Z. Lin y L. Lu, «Improvement and Parallelism of k-Means Clustering Algorithm,» *IEEE Xplore*, vol. 10, n° 3, pp. 277-281, June 2005..
- [71] L. Junhong y J. Lampinen, «A Differential Evolution Based Incremental Training Method for RBF Networks,» *ACM*, Junio 2005..
- [72] J. Kittler, *Reconocimiento de Patrones*, 2002..
- [73] A. Krzyżak, «Nonlinear Function Learning and Classification Using Optimal Radial Basis Function Networks,» *Machine Learning and Data Mining in Pattern Recognition, Springer*, vol. 2123, pp. 217-225, 2001..
- [74] T. Kurban y E. Besdok, «A Comparison of RBF Neural Network Training Algorithms for Inertial Sensor Based Terrain Classification,» *Sensors*, vol. 9, pp. 6312-6329, 2009..
- [75] L. Lanzarini y A. De Giusti, «Redes Neuronales aplicadas al Reconocimiento de Patrones,» *Workshop de Investigadores en Ciencias de la Computación*, pp. 456-459, 2002..
- [76] B. G. H. D. I. a. R. Y. Lemer, «A Comparison of Multilayer Perceptron Neural Network and Bayes Piecewise Classifier for Chromosome Classification,» *IEEE*, vol. 7803, n° 1901, pp. 3472-3477, 1994..
- [77] P. Maji y P. P. Chaudhuri, «RBFFCA: A Hybrid Pattern Classifier Using Radial Basis Function,» *The ACM Digital Library*, vol. 78, n° 3, pp. 369-396, 2007..

- [78] J. McCaffrey, Octubre 2013.. [En línea]. Available: <http://msdn.microsoft.com/es-es/magazine/dn451445.aspx>.
- [79] I. Matadamas, H. Sossa y O. Espinoza, *Aplicación de las Redes Neuronales Pulsantes en el Reconocimiento de Patrones y Análisis de Imágenes*, 2014..
- [80] P. W. McCauley y J. P. Boyd, «Quartic Gaussian and Inverse-Quartic Gaussian radial basis functions: The importance of a nonnegative Fourier transform,» *ELSEVIER*, vol. 65, n° 1, pp. 75-88, 2013..
- [81] M. L. Micó A., *Algoritmos de búsqueda de vecinos más próximos en espacios métricos*, Valencia,, 1996..
- [82] M. Muja y D. G. Lowe, «Scalable Nearest Neighbor Algorithms for High Dimensional Data,» *IEEE Xplore*, vol. 36, n° 11, pp. 2228-2240, November 2014..
- [83] A. S. Nazmul y S. Taib, «A Comparative Study of MLP Networks Using Backpropagation Algorithms in Electrical Equipment Thermography,» *Springer*, vol. 39, pp. 3873-3885, 2014..
- [84] L. Nunes y F. Von Z., «Automatic determination of radial basis functions: an immunity - based approach,» *International Journal of Neural Systems*, vol. 11, n° 6, pp. 523-535, 2001..
- [85] C. Onursal, T. Feyzullah y G. Senol, «An application of multilayer neural network on hepatitis disease diagnosis using approximations of sigmoid activation function,» *ÖZGÜN ARAŞTIRMA*, vol. 42, n° 2, pp. 150-157, 2015..
- [86] F. Ortíz, *Análisis y diseño de redes neuronales CMAC para la identificación y control de sistemas no lineales*, 2008..
- [87] M. Ortíz, H. Håkansson y R. Brånemark, «Real-Time and Simultaneous Control of Artificial Limbs Based on Pattern Recognition Algorithms,» *IEEE TRANSACTIONS ON NEURAL SYSTEMS AND REHABILITATION ENGINEERING*, vol. 22, n° 4, pp. 756-763, July 2014..
- [88] G. Pajares, M. Sanz y J. De la Cruz, *Ejercicios Resueltos de Visión por Computadora*, Alfaomega, 2008..
- [89] G. Pajares, M. Sanz y J. De la Cruz, *Visión por computadora Imágenes digitales y aplicaciones*, 2da. ed., Alfaomega, 2008..
- [90] A. S. Pandya y R. Macy, *Pattern Recognition With Neural Networks in C++*, CRC PRESS and IEEE PRESS, 1995..
- [91] J. Peña y et.al., «An empirical comparison of four initialization methods for the k-means algorithm,» *Pattern Recognition Letters ELSEVIER*, vol. 20, pp. 1027-1040, 1999..
- [92] J. Principe, E. Neil y W. Curt, «Neural and Adaptive Systems Fundamentals Through Simulations,» *Library of Congress Cataloging-in-Publication Data*, 2000..

- [93] V. S. Rao y a. S. Vidyavath, «Comparative Investigations and Performance Analysis of FCM and MFPCM Algorithms on Iris data,» *Indian Journal of Computer Science and Engineering*, vol. 1, n° 2, pp. 145-151, 2010..
- [94] G. X. Ritter y P. Sussner, «Associative memories based on lattice algebra,» *IEEE*, vol. 4, pp. 3570-3575, 1997..
- [95] G. X. Ritter y G. Urcid, «Lattice Algebra Approach to Single-Neuron Computation,» *IEEE*, vol. 14, n° 2, pp. 282-295, 2003..
- [96] G. X. Ritter y M. S. Schmalz, «Learning In Lattice Neural Networks That Employ Dendritic Computing,» *IEEE International Conference on Fuzzy System*, pp. 7-13, July 2006..
- [97] J. Rojas Henríquez y D. Aracena Pizarro, «Segmentación de patentes vehiculares mediante técnicas de agrupamiento en ambientes externos,» *Revista chilena de ingeniería*, n° 2, pp. 172-184, 2013..
- [98] G. Sánchez, *Optimización de Estructuras de Redes Neuronales y aplicaciones*, 2004..
- [99] J. H. Sossa, G. Cortés y E. Guevara, «New Radial Basis Function Neural Network Architecture for Pattern Classification: First Results,» *Springer Link Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications*, vol. 8827, pp. 706-713, 2014..
- [100] H. Sossa y E. Guevara, «Efficient Training for dendrite morphological neural networks,» *Neurocomputing*. <http://dx.doi.org/10.1016/j.neucom.2013.10.031i>, 2014..
- [101] P. Sussner, «Morphological perceptron learning,» *IEEE*, vol. ISIC/CIRA/ISAS Joint Conference, pp. 477-482, 1998..
- [102] T. U. Waikato, 2009.. [En línea]. Available: <http://www.cs.waikato.ac.nz/~ml/weka/citing.html>.
- [103] A. Zabidi, W. Mansor, L. Yoot Khuan y et al., «Classification of Infant Cries with Hypothyroidism Using Multilayer Perceptron Neural Network,» *IEEE International Conference on Signal and Image Processing Applications*, vol. 978, n° 1, pp. 4244-5561, 2009..
- [104] J. Zhao, B. Thörnberg, T. Shi y A. Hashemi, «Color Segmentation on FPGA Using Minimum Distance Classifier for Automatic Road Sign Detection,» *IEEE International Conference on Imaging System and techniques*, vol. 978, n° 1, pp. 516-521, 2012..
- [105] P. Ponce C., *Inteligencia Artificial con Aplicaciones a la Ingeniería*, Alfaomega, 2010..
- [106] W. Xia , Y. Mita y T. Shibata, «A Nearest Neighbor Classifier Employing Critical Boundary Vectors for Efficient On-Chip Template Reduction,» *IEEE Xplore*, pp. 1-14, 2015..
- [107] A. Skomorokhov, «Radial Basis Function Networks in A+,» *ACM*, vol. 32, n° 4, pp. 198-213, Julio 2002..
- [108] L. Shaobo, Z. Jinshan y X. Zongben, «Interpolation and Best Approximation for Spherical Radial Basis

Function Networks,» *Mieczysław Mastyło*, 2013..

- [109] A. Wasim, M. Muhammad y S. S. Muhammad , «A Novel Kernel for RBF Based Neural Networks,» *Hindawi Publishing Corporation*, 2014..
- [110] A. Taher A. y S. A. El-said, «Probabilistic neural network for breast cancer classification,» *Neural Comput & Applic*, pp. 1134-1138, 2013..
- [111] W. Y. N. Wing, D. S. Yeung y E. C. C. TSAG, «The localized generalization error model for single layer perceptron neural network and sigmoid support vector machine,» *World Scientific International Journal of Pattern Recognition and Artificial Intelligence*, vol. 22, n° 1, pp. 121-135, 2008..
- [112] S. Zingen y X. Jian, «Bifurcation and chaos analysis for a delayed two-neural network with a variation slope ratio in the activation function,» *International Journal of Bifurcation and Chao*, vol. 22, n° 5, pp. 1-18, 2012..
- [113] M. Vimaladevi y B. Kalaavathi, «Feed-Forward Back Propagation Neural Network for Ranking Gene Expression Data,» *International Journal of Applied Engineering Research*, vol. 9, n° 21, pp. 11315-11325, 2014..
- [114] I. Stamoulias y E. Manolakos, «Parallel Architectures for the kNN Classifier – Design of Soft IP Cores,» *ACM Transactions on Embedded Computing Systems*, vol. 13, n° 2, pp. 1-21, September 2013..
- [115] G. Soumi y K. D. Sanjay, «Comparative Analysis of K-Means and Fuzzy C-Means algorithms,» *International Journal of Advanced Computer Science and Applications*, vol. 4, n° 4, 2013..
- [116] C. Xiao y M. Lui, «Efficient Mean- Shift Clustering Using Gaussian KD-Tree,» *Journal compilation*, vol. 29, n° 7, pp. 2065-2073, 2010..
- [117] M. Sheikhan, R. Shahnazi y E. Hemmati, «Adaptive active queue management controller for TCP communication networks using PSO-RBF models,» *Springer-Verlag*, vol. 22, n° 5, pp. 933-945, April 2013..
- [118] G. Cortés, J. H. Sossa y P. Rayón, *Red Neuronal Morfológica con Procesamiento en sus Dendritas Utilizada para obtener una imagen binaria*, Primera ed., Ciudad del Carmen, Campeche: Universidad Autónoma del Carmen, 2013..
- [119] C. Yuehu, X. Jingru, Y. Bin y et al., «A novel method for prediction of protein interaction sites based on integrated RBF neural networks,» *ScienceDirect*, vol. 42, n° 4, pp. 402-407, Abril 2012..
- [120] R. Vega y et al., «Retinal vessel extraction using Lattice Neural Networks with dendritic processing,» *ELSEVIER Computers in Biology and Medicine*, 2015..
- [121] A. Fahad y et al., «A Survey of Clustering Algorithms for Big Data: Taxonomy and Empirical Analysis,» *IEEE Transactions on Emerging Topics in Computing*, vol. 2, n° 3, pp. 267-279, September 2014..

- [122] R. Rollet, G. B. Bea N., S. Li W. y et al., «Image classification algorithm based on the RBF neural network and K-means,» *INT. J. REMOTE SENSING*, vol. 19, n° 15, pp. 3003-3009, 1998..
- [123] J. R. Smith y et al., «Speckle Patterns and 2-dimensional spacial model,» *Revista cubana de fisica*, vol. 30, n° 2, pp. 60-65, 2013..
- [124] O. Sung-Kwun y et al., «Design of face recognition algorithm using PCA -LDA combined for hybrid data pre-processing and polynomial-based RBF neural networks : Design and its application,» *Elsevier Expert System with applications*, vol. 40, pp. 1451-1466, 2013..
- [125] H. Xia, C. Shen y et al., «A radial basis function network classifier to maximise leave-one-out mutual information,» *ELSEVIER*, vol. 23, pp. 9-18, 2014..
- [126] C. Yuanfang, P. Xiaodong y et al., «Approaches to multiple attribute decision making based on the correlation coefficient with dual hesitant fuzzy information,» *Journal of Intelligent & Fuzzy Systems*, vol. 26, pp. 2547-2556, 2014..
- [127] S. Ougiaroglou, G. Evangelidis y A. D. Dervos, «A Fast Hybrid Classification Algorithm based on the Minimum Distance and the k-NN Classifiers,» *ACM*, vol. 978, n° 1, pp. 97-104, 2011..