



UAEM | Universidad Autónoma
del Estado de México

**UNIVERSIDAD AUTÓNOMA DEL ESTADO DE
MÉXICO**

INGENIERÍA EN COMPUTACIÓN

**Análisis comparativo en la detección de glaucoma
mediante técnicas probabilísticas y redes neuronales**

Tesis que presentan

MARCO ANTONIO ZARATE JIMENEZ

XAVIER ALEJANDRO SANDOVAL MARTÍNEZ

Para obtener el Grado de

Ingeniero en Computación

Asesor de Tesis:

DR. JAIR CERVANTES CANALES

Texcoco, Estado de México.

Mayo del 2023

Índice general

Abstract	IX
Resumen	XI
Índice general	XIII
Índice de figuras	XVII
Índice de tablas	XIX
1. Introducción	1
1.1. Planteamiento del problema	3
1.2. Justificación	4
1.3. Objetivos	5
1.3.1. Objetivos Generales	5
1.3.2. Objetivos específicos	5
1.4. Hipótesis	6
2. Marco Teórico	7
2.1. Detección de Glaucoma	7
2.1.1. Tipos de glaucoma	13
2.1.2. Tratamiento	15
2.1.3. Proceso de Detección de Glaucoma	20
2.2. Técnicas de clasificación	20
2.2.1. Probabilidad	20
2.2.2. Teorema de bayes	22
2.2.3. Teorema de probabilidad total	23
2.2.4. Algoritmo de Naive Bayes para la clasificación	24
2.2.5. Modelo bayesiano inicial	26
2.2.6. Redes Bayesianas	26
2.3. Redes neuronales	28

2.3.1.	Redes neuronales Artificiales y biológicas	30
2.3.2.	Perceptrón.....	32
2.3.3.	Algoritmo backpropagation.....	34
2.3.4.	Redes neuronales convolucionales.....	36
2.4.	Extracción de Características	38
2.4.1.	Técnicas de Extracción de Características.....	40
2.4.2.	Técnicas de Selección de Características	41
2.4.3.	Técnicas de Aprendizaje Automático	42
2.4.4.	Enfoques de Reducción de Dimensionalidad	44
	Selección de características	44
	Extracción/Transformación de características	46
	Análisis De La Selección De Diferentes Características Y Técnicas De Extracción De Características	46
2.4.5.	Métodos de extracción que usa como base el método bayesiano.....	49
2.4.6.	Detección de puntos característicos.	49
3.	Antecedentes	53
3.1.	Modelado del Glaucoma y Diagnóstico asistido por Red Neuronal	53
3.1.1.	Modelado De Cuadros De Fondo Y Glaucoma.....	54
3.1.2.	Imágenes De Fondo Artificial.....	54
3.1.3.	Preprocesamiento	55
3.1.4.	Preprocesamiento De Texturas.....	55
3.2.	Investigación Universidad Autónoma del Estado de México	56
3.3.	Clasificador de redes neuronales para el diagnóstico de glaucoma	58
	Material Y Métodos.....	59
4.	Metodología	61
4.1.	Pre procesamiento.....	62
4.2.	Segmentación	62
4.3.	Extracción de características.....	64
4.4.	Clasificación e identificación	65
4.5.	Análisis de desempeño	65
5.	Resultados experimentales	68
5.1.	Conjuntos de Imágenes	69
5.1.1.	Conjunto de Imágenes 1	69

	XVI
5.1.2. Conjuntos de Imágenes Singapore Malay Eye Study (SiMES) . . .	70
5.1.3. Normalización de datos	72
Normalización estadística.....	72
Aplicaciones	73
Componente Normalizar datos.....	73
Configurar Normalize Data	74
5.2. Desempeño de clasificadores (Conjunto de datos 1).....	75
5.3. Desempeño de clasificadores utilizando Conjunto de datos SiMES dataset	77
6. Conclusiones	80
Bibliografía	81

Índice de figuras

2.1. Pasos empleados para la detección de glaucoma.....	20
2.2. Teorema de probabilidad total. Figura tomada de [23].....	23
2.3. Algoritmo de clasificación Naive Bayes "Figura tomada de [4]".....	25
2.4. Algoritmo Backpropagation, Figura tomada de [1].....	34
2.5. Técnicas de extracción de características utilizadas en la detección de glaucoma. Figura "Tomada de [16]".....	41
2.6. Técnicas de extracción de características utilizadas en la detección de glaucoma. Figura "tomada de [16]".....	42
4.1. Pasos empleados para la detección de glaucoma.....	61
4.2. Imagen original (izquierda) e imágenes preprocesadas con filtro Gaussiano 5×5 (centro) y filtro promedió 5×5 (derecha).....	62
4.3. Obtención de región de interés utilizando segmentación de Otsu.....	63
5.1. Conjunto de datos 1 utilizado con imágenes Glaucomatosas.....	70
5.2. Conjunto de datos SiMES utilizado con imágenes no glaucomatosas.....	71
5.3. Técnicas de normalización de datos.....	72
5.4. Gráficas AUC-ROC del clasificador Naive Bayes para las 3 diferentes clases	76
(a). Clase 1 Vs 2 y 3.....	76
(b). Clase 2 Vs 1 y 3.....	76
(c). Clase 3 Vs 1 y 2.....	76
5.5. Gráficas AUC-ROC de lo clasificadores Backpropagation, Naive Bayes y red Bayesiana.....	78
(a). Redes neuronales.....	78
(b). Naive Bayes.....	78
(c). Redes Bayesianas.....	78

Índice de tablas

2.1. Comparación entre Perceptron y Backpropagation	36
5.1. Resultados utilizando todas las características	76
5.2. Resultados para la detección de glaucoma	77

Capítulo 1

Introducción

El glaucoma es una afección ocular que conduce a la ceguera permanente cuando la enfermedad progresa a una etapa avanzada. Esta enfermedad neurodegenerativa se caracteriza principalmente por la lesión del nervio óptico debido a una presión intraocular (PIO) elevada o inapropiada en el ojo y/o pérdida de flujo sanguíneo al nervio óptico. Esta enfermedad es la causa principal de la ceguera permanente, ya que se vuelve patológicamente alta, a veces elevándose severamente a 60-70mm HG (milímetros de mercurio) esto tomando en cuenta que la presión ocular normal varía entre 12 y 22 mm Hg, y la presión ocular que supere los 22 mm Hg, se considera superior a la normal. La presión intraocular aumenta debido a la incapacidad del ojo para drenar el exceso de líquido. La presión empuja contra el nervio óptico, dañando las fibras nerviosas, que transmite imágenes al cerebro. Las fibras nerviosas lesionadas causan el deterioro de la capa de fibras nerviosas de la retina (RNFL) y dan como resultado una relación copa disco agrandada (CDR) (o ahuecamiento) y el disco óptico (OD) o la cabeza del nervio óptico (ONH)[1].

Entre los nuevos métodos que se han propuesto para la detección del glaucoma, las imágenes en color del fondo de ojo se han utilizado a menudo en combinación con algoritmos de procesamiento de imágenes, para ayudar en la detección y clasificación de enfermedades oculares. Se han propuesto otros estudios que utilizan algoritmos de procesamiento de imágenes[32][3][17]. Podemos encontrar trabajos que se centran en la localización y segmentación del disco óptico y numerosos algoritmos de detección de glaucoma basados en la extracción de características de la imagen o versiones transformadas de la imagen para entrenar diferentes tipos de clasificadores.

Enfermedad neurodegenerativa provocada por el daño en el nervio óptico y el aumento de la presión intraocular, lo que repercute en el campo de visión disminuya progresivamente[4]. En un estudio de prevalencia de glaucoma de los datos publicados en

todo el mundo, se encontraron que para el año pasado (2020), más de 11,1 millones de personas quedarán ciegas bilateralmente por glaucoma primario [35].

Básicamente, existen dos tipos principales de glaucoma:

- El glaucoma de ángulo abierto, que es la forma más común de glaucoma, que representa al menos el 90 % de todos los casos de glaucoma, caracterizado por el ángulo amplio y abierto entre el iris y la córnea, además de que se desarrolla lentamente.
- El otro tipo es el glaucoma de ángulo cerrado, una forma menos común de glaucoma, tiene un ángulo cerrado o estrecho entre el iris y la córnea y, se desarrolla rápidamente, este tipo tiene síntomas y daños que suelen ser muy notorios [24].

En esta tesis, se implementan algoritmos de aprendizaje máquina para la detección automática de glaucoma y retinopatía diabética. Para ese propósito se utilizan dos de los algoritmos de aprendizaje máquina más utilizados (clasificación Bayesiana y Redes neuronales).

En esta tesis se exploran dos conjuntos de técnicas que permiten clasificar retinopatía y glaucoma diabético utilizando fotografías de fondo ocular. Los algoritmos utilizados segmentan la región deseada y extraen características utilizando diferentes algoritmos de extracción de características. Con estas características extraídas se entrenan dos conjuntos de algoritmos y se evalúan los resultados obtenidos.

Los resultados pueden ayudar a agilizar y reducir los costos de diagnóstico profesional, al mismo tiempo mejorar la precisión en el diagnóstico.

1.1. Planteamiento del problema

El correcto diagnóstico médico de una enfermedad es muy importante para aplicar un tratamiento adecuado que permita reducir los efectos de esa enfermedad. El diagnóstico de la retinopatía y glaucoma diabético es muy importante y permite reducir significativamente los efectos si es identificado y tratado a tiempo. La identificación y diagnóstico siempre es llevado a cabo por un especialista que es entrenado por años. Sin embargo, como cualquier diagnóstico sujeto a una evaluación humana, esta es susceptible de errores.

Los algoritmos de aprendizaje máquina actuales han sido implementados en diferentes campos de la vida real y en los últimos años se han obtenido resultados sorprendentes en el diagnóstico médico. En esta tesis se implementan estas técnicas para identificar la retinopatía y glaucoma.

1.2. Justificación

El glaucoma es la tercera causa más prevalente de deterioro visual y ceguera en los Estados Unidos, después de las cataratas y la degeneración macular del envejecimiento. "Los datos de la Encuesta de Ojos de Baltimore basada en la población sugieren que más de 15 millones de estadounidenses pueden tener glaucoma. 1.6 millones de daños en el campo visual y 150,000 ceguera bilateral debido al trastorno ". La información disponible es insuficiente para proporcionar datos estrictos sobre la incidencia [25].

Visto los datos alarmantes sobre el glaucoma, los algoritmos desarrollados en esta tesis pretenden ayudar a identificar eficientemente el glaucoma en una etapa temprana y a un costo muy bajo. Esto ayudará a reducir de manera significativa el número de gente que pierda total o parcial el sentido de la vista, gracias a la detección temprana del glaucoma de una manera rápida y sencilla.

En los últimos años se han implementado diferentes algoritmos para diagnóstico automático. Estos algoritmos permiten:

1. Ayudar en el diagnóstico del profesional en una primera fase y en fases posteriores, mejorar significativamente la precisión del diagnóstico del profesional. Esto es debido a que los algoritmos de aprendizaje máquina pueden identificar adecuadamente patrones importantes a partir de millones de datos con incluso miles de características, algo que el ser humano no puede hacer.
2. Reducir los costos en el diagnóstico. Para un diagnóstico acertado los profesionales se basan en diferentes análisis clínicos para realizar un diagnóstico adecuado. El desarrollo de algoritmos de identificación basados en fondo ocular permite que a través de una imagen se obtenga un diagnóstico acertado. Esto permite disminuir significativamente los costos de diagnóstico.
3. Reducción de tiempos de diagnóstico. El diagnóstico requiere la experiencia de un profesional que en muchas ocasiones no se tiene en algunos lugares. Esto provoca dilaciones y demoras en el diagnóstico adecuado. El desarrollo de estos algoritmos ayudará a disminuir los tiempos de espera y agilizar significativamente un diagnóstico adecuado.

1.3. Objetivos

1.3.1. Objetivos Generales

EL objetivo general de la tesis es implementar algoritmos basados en clasificación Bayesiana y redes neuronales para la detección de retinopatía y glaucoma basados en imágenes de fondo ocular.

1.3.2. Objetivos específicos

1. Obtener el conjunto de datos a utilizar
2. Aplicar preprocesamiento a las imágenes
3. Extraer características necesarias
4. Implementar los algoritmos de clasificación para la automatización de la detección del glaucoma y retinopatía.
5. Análisis de los resultados obtenidos.

1.4. Hipótesis

¿Es posible clasificar glaucoma y retinopatía con una precisión aceptable a partir de imágenes de fondo ocular utilizando Clasificación Bayesiana y Redes neuronales?

Capítulo 2

Marco Teórico

2.1. Detección de Glaucoma

El nombre de glaucoma proviene del término *glaukos* que quiere decir, verde y fue utilizado por los autores antiguos debido al aspecto verdoso que algunas veces presenta la pupila en estos enfermos. Ellos consideraban el glaucoma como una forma especial de catarata y esto fue mantenido por los oculistas hasta principios del siglo XVIII cuando Briseau, en 1709, en el "Tratado de catarata y glaucoma" dio a conocer que la catarata era una cosa distinta al glaucoma. Corresponde, sin embargo a Albrech Von Graefe (1828-1870) el mérito de haber relacionado directamente, aunque con cierta inseguridad, la sintomatología de algunos casos de glaucoma con el aumento de la presión interna del ojo. En la actualidad se considera que el glaucoma es una neuropatía óptica crónica y progresiva que se caracteriza por una pérdida de la capa de fibras nerviosas de la retina, una excavación y palidez progresiva de la pupila y el desarrollo de defectos del campo visual. Va asociado, aunque no en todos los casos, a un aumento de la presión intraocular (PIO). Esta enfermedad se clasifica de varias maneras: según la forma de alteración del drenaje del acuoso en: glaucoma de ángulo abierto o de ángulo estrecho; dependiendo de la presencia o no de factores asociados en: primarios y secundarios; y según la edad en: congénito, infantil, juvenil y del adulto. El más frecuente es el glaucoma primario de ángulo abierto (GPAA), que representa el 60% de todos. No se relaciona con otra alteración ocular, el ángulo camerular está abierto y puede ser bilateral, aunque con más frecuencia es asimétrico. Desde el punto de vista epidemiológico, la prevalencia del glaucoma tiene distintos comportamientos. Según distintos autores, en poblaciones sin antecedentes hereditarios es de 0.4 a 0.8% y asciende cuando hay antecedentes a entre 3.5 y 19%. (7.8) Existen diferentes factores de riesgo para el desarrollo de esta entidad, estos pueden ser oculares y no oculares, muchos de los cuales siguen siendo desconocidos. Entre los factores no oculares los datos son consistentes

en apoyar la edad como un factor de riesgo importante. Su incidencia es de 1.5 % en la población total y del 3 al 4 % en los grupos de más de 40 años y que alrededor de un 25 % de estos casos no se detectan. Aunque algunos autores niegan la importancia que juegan los antecedentes patológicos personales se ha demostrado la relación que existe entre el GPAA y antecedentes personales de diabetes mellitus, hipertensión arterial (HTA), enfermedades cardiovasculares, tabaquismo y consumo de alcohol. Mientras que la prevalencia del glaucoma es de 1.5 % a 2.0 % en la población general, del 10 % al 15 % de los familiares de individuos con GPAA están propensos a desarrollar la enfermedad.

El glaucoma es una enfermedad degenerativa que afecta la visión, provocando un daño en el nervio óptico que termina en la pérdida de la visión. Las técnicas clásicas para detectarlo han sufrido un gran cambio desde la irrupción de las técnicas de aprendizaje automático en el procesamiento de imágenes de fondo de ojo. Varios trabajos se centran en el entrenamiento de una red neuronal convolucional (CNN) por fuerza bruta, mientras que otros utilizan técnicas de segmentación y extracción de características para detectar el glaucoma [31]. En este trabajo se desarrolla, entrena y prueba una herramienta de ayuda al diagnóstico para la detección de glaucoma mediante imágenes de fondo de ojo. Consta de dos subsistemas que se entrenan y prueban de forma independiente, y combinan sus resultados para mejorar la detección del glaucoma. El primer subsistema aplica el aprendizaje automático y técnicas de segmentación para detectar disco óptico y copa de forma independiente, combinarlos y extraer sus características físicas y posicionales [31]. El segundo aplica técnicas de transferencia de aprendizaje a una CNN preentrenada para detectar glaucoma a través del análisis de las imágenes completas del fondo de ojo. Los resultados de ambos sistemas se combinan para discriminar los casos positivos de glaucoma y mejorar la detección final. Los resultados muestran que este sistema logra una mayor tasa de clasificación que trabajos anteriores. El sistema también proporciona información con base a la sugerencia diagnóstica propuesta que puede ayudar al oftalmólogo a aceptarla o modificarla.

El término Glaucoma se utiliza para un grupo de neuropatías progresivas que afectan la visión (en su mayoría bilaterales) y se caracterizan por la pérdida de células ganglionares de la retina y el daño en la cabeza del nervio óptico, lo que provoca la pérdida del campo visual y, finalmente, la ceguera. Además, es una de las principales causas de daño visual irreversible y ceguera en todo el mundo (segunda causa en Europa). Existen dos tipos principales de glaucoma cuyas causas son bien conocidas:

- Glaucoma de ángulo abierto (GAA): la forma más común de glaucoma (al menos el 90 % de todos los casos de glaucoma). Eso es causado por la obstrucción lenta de los canales de drenaje, lo que resulta en un aumento de la presión ocular. “Ángulo abierto” significa que el ángulo donde el iris se encuentra con la córnea es tan ancho y abierto como debería ser (también llamado glaucoma primario o crónico).
- Glaucoma de ángulo cerrado (ACG): es causado por canales de drenaje bloqueados, lo que resulta en un aumento repentino de la presión intraocular. También se le llama glaucoma agudo o glaucoma de ángulo estrecho y, a diferencia de OAG, ACG es el resultado del ángulo entre el iris y el cierre de la córnea. Existen otros tipos de glaucoma como el glaucoma de tensión normal (se daña el nervio óptico aunque la presión ocular no sea muy alta, por lo que no se sabe bien por qué se produce este daño), el glaucoma congénito (se da en los bebés cuando hay una tensión incorrecta o desarrollo incompleto de los canales de drenaje del ojo durante el período prenatal), y varias variantes de OAG y ACG. La mayoría de ellos no están bien estudiados y sus causas aún no están definidas.

Para poder determinar si un paciente tiene glaucoma o no, han aparecido muchos avances desde los primeros ensayos clínicos. Los mecanismos clásicos de detección de glaucoma se basan en la verificación de cinco factores clave: tonometría, oftalmoscopia, perimetría, gonioscopia y paquimetría. Dependiendo de los resultados de cada examen de forma independiente, el médico podrá seguir realizando los demás o no.

- **Tonometría:** mide la presión dentro del ojo. El rango de presión normal está entre 12 y 22 mmHg. La mayoría de los casos de glaucoma se diagnostican con una presión superior a 20 mmHg; sin embargo, algunas personas pueden tener glaucoma a presiones entre 12 y 22 mm Hg, por lo que es posible que se requieran otros exámenes.
- **Oftalmoscopia:** ayuda a examinar la forma y el color del nervio óptico en busca de daño por glaucoma. Si la presión intraocular (PIO) no está dentro del rango normal o si el nervio óptico se ve inusual, se necesitan más exámenes.
- **Perimetría:** prueba de campo visual que produce un mapa del campo de visión completo. Esta prueba ayudará a determinar si su visión se ha visto afectada por el glaucoma.
- **Gonioscopia:** ayuda a determinar si el ángulo donde el iris se encuentra con la córnea es abierto y ancho (un posible signo de glaucoma crónico de ángulo abierto) o estrecho y cerrado (un posible signo de ángulo cerrado o glaucoma agudo).
- **Paquimetría :** mide el grosor de la córnea. El grosor de la córnea tiene el potencial de influir en las lecturas de la presión ocular; entonces, con esta medida, es más fácil entender las lecturas de la PIO.

Como se detalló anteriormente, no existe un único procedimiento para diagnosticar el glaucoma debido a las diferentes características oculares de cada paciente. Además, esos exámenes deben ser interpretados por el médico antes de hacer un diagnóstico. Actualmente, las técnicas de diagnóstico de glaucoma basadas en el análisis de imágenes médicas están ganando popularidad frente a las pruebas más clásicas. En estos casos es necesario observar varias características de la estructura de la retina: la cabeza del nervio óptico (ONH), la copa, la atrofia peripapilar, la capa de fibras nerviosas de la retina, etc. En una imagen de fondo de ojo, la ONH es un área brillante y redondeada, y no es un área más pequeña y redondeada dentro de la ONH llamada copa. La atrofia peripapilar aparece como una media luna que coincide con el área fuera de la ONH. La

capa de fibras nerviosas de la retina también se encuentra fuera de la ONH, que tiene texturas estriadas de color blanco. En general, para identificar las características necesarias para diagnosticar un glaucoma mediante visión artificial, se pueden aplicar dos tipos de técnicas: la segmentación y la extracción de características. Varios de los métodos más populares implican procesos de localización y segmentación, como umbrales y contornos activos. Se han desarrollado métodos adicionales, como fuzzy c-means. Estos métodos a menudo clasifican erróneamente el área ONH; por lo que, para superar este inconveniente, normalmente es necesario aplicar operaciones morfológicas. Por otro lado, se han desarrollado varios métodos para la extracción de características de textura de ONH, ya que esta es la principal característica utilizada para detectar el glaucoma. Los métodos de wavelet y de espectro de orden superior (HOS) son los métodos más populares para la extracción de características. Algunos trabajos utilizan la transformada wavelet discreta (DWT) y HOS aplicados con un clasificador de máquina de vectores de soporte (SVM) como . A otros les gusta usar el Análisis de Componentes Principales (PCA) para reducir las características obtenidas usando DTW. Los trabajos mencionados anteriormente fueron solo algunos ejemplos de la evolución en las técnicas de detección de glaucoma. Sin embargo, el estudio de las imágenes médicas en general ha experimentado un gran avance con la inclusión de sistemas de Machine Learning capaces de extraer de forma automática las características necesarias para realizar un diagnóstico correcto [9].

Factores de riesgo

- Historia familiar de glaucoma
- Melanodermias
- Enfermedades oculares como:
 - Miopía de alto grado
 - Exfoliación capsular
 - Dispersión pigmentaria
- Hipotensión arterial
- Edad avanzada
- Diabetes mellitus
- Vasoespasmo
- Arterioesclerosis
- Oclusión carotídea

2.1.1. Tipos de glaucoma

El glaucoma de ángulo abierto y de ángulo cerrado a su vez se subdivide en glaucoma primario o secundario, dependiendo de la causa que lo ocasiona.

En el glaucoma primario, tenemos al glaucoma primario de ángulo abierto (GPAA) el cual es una entidad que cursa con neuropatía óptica, progresiva y crónica. Es el más frecuente, en su etiopatogenia aún existen factores desconocidos que contribuyen al daño y no corresponden a causas identificables, con ángulo camerular abierto, normalmente cursa con PIO elevada, aunque existen también casos con PIO normal.

El glaucoma primario de ángulo cerrado se produce por un cierre del ángulo iridocorneal se caracteriza por neuropatía óptica asintomática al inicio y evidente en casos avanzados, siendo imprescindible su detección temprana, seguimiento y realización de pruebas funcionales y estructurales para identificar y evaluar su posible progresión, todo esto a través tanto del examen clínico como de las pruebas complementarias.

Con respecto al **glaucoma secundario**, existen dos tipos de glaucoma que cursan con ángulo camerular abierto, cuya fisiopatología se caracteriza por el cúmulo de material anormal a nivel de la malla trabecular con aumento de la resistencia al flujo de salida del humor acuoso y aumento de la PIO subsecuente que a su vez ocasiona neuropatía óptica. Nos referimos al Glaucoma Pigmentario (GP) y al Glaucoma Pseudoexfoliativo (GPXE), los cuales a pesar de tener menor incidencia a la del GPAA tienen peor pronóstico visual para el paciente y una mayor tasa de progresión.

El síndrome de dispersión **pigmentaria (SDP)**, se caracteriza por la disrupción del pigmento del iris debido a un bloqueo pupilar inverso, acumulándose pigmento en la capsula posterior y depositándose en el segmento anterior especialmente en la inserción zonular y cápsula posterior del cristalino (signos de zentmayer y sheie) siendo parte de su diagnóstico clásico la observación del huso de Krukenberg, así como iluminación radial medio periférica o transiluminación y pigmentación densa a nivel trabécular. Fue descrito por Krukenberg en 1899 [29] y el glaucoma pigmentario (GP) es consecuencia del aumento de la resistencia la salida del humor acuoso con el subsecuente aumento de la PIO. Se presentan causas anatómicas en las que es más frecuente el SDP, como pacientes miopes con iris cóncavos. El GP suele ser bilateral y afecta personas en la cuarta década de la vida, de sexo masculino y, aunque su prevalencia no es

alta, es la causa más común de glaucoma secundario en adultos jóvenes

El **glaucoma congénito primario de ángulo abierto (GCP)**, también denominado glaucoma infantil primario, es una enfermedad rara que aparece clínicamente aislada constituyendo una entidad en sí misma. No se encuentra asociada a síndromes ni a otras anomalías oculares que el desarrollo anormal de la malla trabécular lo que origina el aumento de la presión ocular [29]. GCP parece ser el resultado de una alteración del desarrollo de tejidos del ángulo de la cámara anterior derivados de células de la cresta neural. En general es de presentación esporádica, aunque algunos de esos pacientes muestran un patrón recesivo con penetrancia variable y posiblemente una herencia multifactorial.

2.1.2. Tratamiento

El tratamiento del glaucoma se centra en reducir la presión intraocular (PIO), que sigue siendo el principal método de tratamiento. La PIO objetivo para un ojo en particular es establecido a partir de una serie de factores, incluida la presión previa al tratamiento, el riesgo de progresión, el daño del nervio óptico, y edad. Es recomendado por la Academia Americana de Oftalmología cuyos tratamientos iniciales tienen como objetivo reducir la PIO en el glaucoma primario de ángulo abierto (GAA) en un 25 % de línea de base.

TERAPIAS MÉDICAS

El primer enfoque en la gestión de OAG es generalmente a través de medicamentos tópicos. Una serie de gotas pueden utilizarse para reducir la PIO y se puede dividir en 5 principales clases:

- Análogos de prostaglandinas
- Betabloqueantes
- Diuréticos
- Agonistas
- Colinérgicos
- Agonistas alfa.

Monoterapia

con análogos de prostaglandinas o betabloqueantes es más a menudo la primera línea. Disminuyen los análogos de prostaglandinas PIO al reducir la resistencia al flujo de salida, lo que da como resultado aumento del flujo de humor acuoso a través de la uveoescleral vía. Los betabloqueantes, por otro lado, reducen la PIO disminuyendo la formación acuosa. La tolerabilidad ocular de los betabloqueantes es favorable; sin embargo, pueden causar efectos secundarios cardíacos o respiratorios. En el pasado, los betabloqueantes eran la medicación tópica de primera línea más común. Los análogos de prostaglandinas se han demostrado que reduce la PIO más que los betabloqueantes en varios estudios, 12-14 con menos efectos secundarios sistémicos. Durante la década de 1990, el uso de análogos de prostaglandinas aumentó, mientras que la de los betabloqueantes disminuyó. Un estudio realizado en Ontario, Canadá, demostró un aumento

en el uso de medicamentos para el glaucoma entre 1992 y 2004, particularmente los análogos de prostaglandinas, con una disminución posterior en el número de cirugías de glaucoma [33]. En Ontario, el número de medicamentos para el glaucoma dispensado casi se duplicó entre 1992 y 2004. Además, el aumento en los análogos de prostaglandinas dispensados se correlacionó fuertemente ($p < 0.001$) con una disminución del número de trabeculectomías realizadas [33].

Terapia de Láser

El manejo médico no reduce la PIO al objetivo niveles en todos los pacientes, y algunos continúan experimentando deterioro del nervio óptico a pesar de los tratamientos antes mencionados. La trabeculoplastia con láser de argón se introdujo como una modalidad de tratamiento para OAG por Wise y Witter²⁴ [11]. El mecanismo no se comprende bien, aunque se cree ser causado por la energía térmica dirigida hacia la malla trabécular, que causa cicatrices focales y por lo tanto abre espacio en estructuras adyacentes, o atribuible a la inflamación de citocinas y fagocitosis, que induce cambios estructurales con mejoría en la salida. El número total de procedimientos de trabeculoplastia con láser y los tratamientos bilaterales con láser en el mismo día aumentaron drásticamente en la primera mitad de la década de 2000, debido a la llegada de trabeculoplastia selectiva con láser (SLT). En Ontario, Canadá, el volumen de trabeculoplastias láser bilaterales en el mismo día aumentó de 15,3 por 1000 con GAA en 2000 a 74,7. Además, el número de láser Las iridotomías mostraron un aumento de 1,7 veces entre 2000 y 2012. en Ontario.²⁹ La SLT fue introducida por Latina et al. en 1998 y es actualmente, la terapia con láser más utilizada y aceptada para el tratamiento de OAG.³¹⁻³⁵ SLT es menos traumático que ALT y utiliza un Nd : YAG conmutado Q de frecuencia duplicada láser (Selecta 7000 ; Coherent Medical Group , Santa Clara , Calif .) Para lograr resultados similares sin causar visible daño a las estructuras de la malla trabecular . El exacto El mecanismo por el cual la SLT reduce la PIO no se comprende bien . El daño estructural mínimo a la malla trabécular favorece las teorías de que SLT actúa a nivel celular sin efectos térmicos . Esto podría ser a través de la fagocitosis de los desechos de la malla trabécular o por estimular el crecimiento de la red trabecular.

TERAPIAS QUIRÚRGICAS

Cuando la medicación y la terapia con láser por sí solos no son eficaces en el control de la PIO, incisiones más invasivo está indicada la cirugía, como trabeculectomía o GDI. En general, ha habido una reducción en el número de cirugías de glaucoma realizadas en Canadá, Estados Unidos, los Países Bajos, Australia, Inglaterra, Escocia y Gales.^{16,26,27,66-71} Esta disminución puede atribuirse a la introducción de una farmacoterapia mejorada para el glaucoma en la década de 1990. En un estudio [2], que examinó el glaucoma tasas de procedimientos quirúrgicos en Canadá, una disminución del 29 % en se observó número de trabeculectomías realizadas.

Implantes de drenaje de glaucoma

En los últimos años, ha aumentado el interés en GDI. Tradicionalmente, los GDI se utilizaban para el glaucoma refractario, aunque han ido ganando favoritismo, incluso en casos de glaucoma no refractario. En un estudio, que examinó las tasas de procedimientos quirúrgicos de glaucoma en Estados Unidos, un aumento del 184 % en el uso de GDI, de 2728 en 1995 a 7744 en 2004 [2]. Encuestas de miembros del American Glaucoma la sociedad realizada en 1996, 2002 y 2008 también mostró un aumento significativo en el uso de GDI en comparación con trabeculectomía. En este estudio [2], los pacientes que habían Trabeculectomía previa y / o extracción de cataratas y glaucoma no controlado (con PIO Z18) fueron aleatorizados a cualquier cirugía de derivación de tubo (glaucoma de Baerveld de 350 mm² implante) o trabeculectomía con mitomicina C (Mutamicina; Bristol-Myers Squibb, Nueva York, N.Y.) se encontró que los pacientes que se sometieron a una cirugía de derivación de tubo tuvo una mayor tasa de éxito en comparación con la trabeculectomía durante 5 años de seguimiento.

Cirugía de glaucoma no penetrante

Cirugía de glaucoma no penetrante (NPGS), como esclerectomía profunda (DS) y viscocanalostomía (VC), se popularizaron en la década de 1990 como una alternativa a trabeculectomía, con menos complicaciones. La diferencia entre NPGS y trabeculectomía es que los procedimientos implican la creación de una membrana de filtración (la membrana de Trabeculo -Descemet) en lugar de un esclerostomía. La mayoría de los estudios coinciden en que NPGS tiene una menor complicación en la tasa que la trabeculectomía, aunque su eficacia en los términos de la reducción de la PIO siguen siendo un tema de debate. Algunos estudios sugieren que las técnicas NPGS tienen capacidades de reducción de la PIO como la trabeculectomía estándar, mientras que otros sugieren que NPGS es inferior en la reducción de la PIO. Estudios prospectivos aleatorizados han encontrado que las tasas de éxito de SD y trabeculectomía son similares. Cillino et al. no encontró diferencia significativa en los resultados entre las 2 técnicas, pero concluyó que la trabeculectomía fue más adecuada en pacientes con PIOs más altas. Un metanálisis de 10 controles aleatorizados Los ensayos que comparan trabeculectomía y VC concluyeron que la trabeculectomía tuvo un mayor efecto de reducción de la presión que VC, pero con un perfil de riesgo más alto. En un estudio prospectivo aleatorizado de 50 ojos, el 42 % de los pacientes en el grupo de trabeculectomía tuvieron un resultado exitoso en comparación con el 21 % en el grupo VC. El principal beneficio de usar NPGS es su mayor seguridad.

2.1.3. Proceso de Detección de Glaucoma

El proceso genérico de detección automatizada de glaucoma es ilustrado en

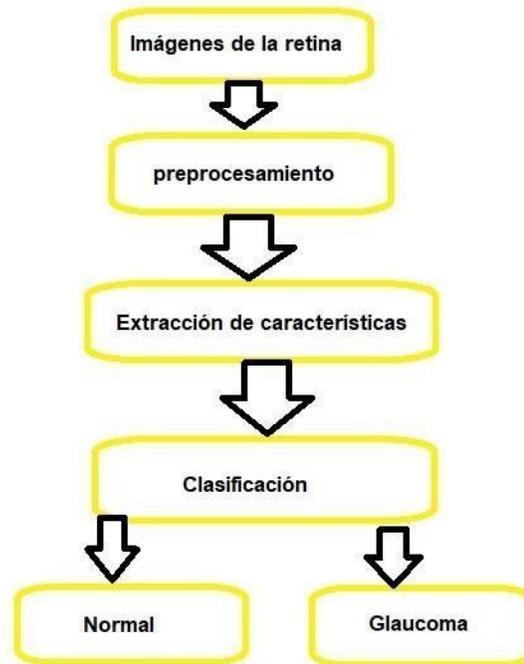


FIGURA 2.1: Pasos empleados para la detección de glaucoma

2.2. Técnicas de clasificación

2.2.1. Probabilidad

Estas permiten de una manera conocer la probabilidad que cada individuo a estudio tiene de ser incluido en la muestra a través de una selección al azar. Estas son:

Aleatorio estratificado: Se determinan los estratos que conforman la población blanco para seleccionar y extraer de ellos la muestra (se define como estrato a los subgrupos de unidades de análisis que difieren en las características que van a ser analizadas). La base de la estratificación se basa en variable como edad, sexo, nivel socioeconómico, etc. Entonces, se divide la población compuesta por n individuos, en x subpoblaciones o estratos, con base a variables importantes para la conducción del estudio, y de

tamaños respectivos $N_1, N_2, N_3, N_4, \dots, N_k$; y realizando en cada una de estos estratos, muestreos aleatorios simples de tamaño n_i ; para finalmente definir cuantos elementos de la muestra se han de seleccionar de cada uno de los estratos; para lo cual se dispone de las siguientes opciones: asignación proporcional (el tamaño de la muestra de cada estrato es proporcional al tamaño del estrato que le dio origen, respecto a la población total) y asignación óptima (el tamaño de la muestra de cada estrato, son definidos por quien hace el muestreo) (Bai et al., 2013).

Aleatorio sistemático: Cuando el criterio de distribución de los sujetos a estudio en una serie es tal, que los más similares tienden a estar más cercanos. Este tipo de muestreo suele ser más preciso que el aleatorio simple, debido a que recorre la población de forma más uniforme. De este modo, se seleccionará cada hésimo caso (Arias-Gómez et al.).

Por conglomerados: Consiste en elegir de forma aleatoria ciertos barrios o conglomerados dentro de una región, ciudad, comuna, etc., para luego elegir unidades más pequeñas como; cuadras, calles, etc. y finalmente otras más pequeñas, como escuelas, consultorios, hogares (una vez elegido esta unidad, se aplica el instrumento de medición a todos sus integrantes). Si se desea realizar un estudio de prevalencia o una encuesta en habitantes de una localidad, el muestreo aleatorio simple es complejo y de alto costo, ya que estudiar una muestra de tamaño "n", supone enviar encuestadores a "x" puntos diferentes de la misma; de tal forma que, en cada uno de estos puntos, solo se aplicará una encuesta.

2.2.2. Teorema de bayes

Fue publicado por primera vez en 1763 [13] [12], dos años después de la muerte de su creador: el matemático y teólogo inglés Thomas Bayes. Sea B_1, \dots, B_n una partición de Ω tal que $P(B_i)$ es diferente que 0, 1, ..., n. Sea A un evento tal que $P(A)$ diferente que 0. Entonces para cada $j = 1, 2, \dots, n$.

$$P(B_j | A) = \frac{P(A|B_j)P(B_j)}{\sum_n P(A|B_i)P(B_i)} \quad (2.1)$$

Demostración. Por definición de probabilidad condicional y después usando el teorema de probabilidad total, tenemos que:

$$P(B_j | A) = \frac{P(A \cap B_j)}{P(A)} = \frac{P(A|B_j)P(B_j)}{\sum_{i=1}^n P(A|B_i)P(B_i)} \quad (2.2)$$

Cuando la partición de Ω consta de los elementos B y Bc, el teorema de Bayes para el evento B adquiere la forma:

$$P(B|A) = \frac{P(A|B)P(B)}{P(A|B)P(B) + P(A|B^c)P(B^c)} \quad (2.3)$$

Y cuando la partición consta de un numero infinito numerable de elementos, el teorema de Bayes tiene la siguiente extensión ligera para $j = 1, 2, \dots, n$

$$P(B_j | A) = \frac{P(A|B_j)P(B_j)}{\sum_{i=1}^{\infty} P(A|B_i)P(B_i)} \quad (2.4)$$

2.2.3. Teorema de probabilidad total

Sea Ω el espacio muestral de un experimento aleatorio. Decimos que la colección de eventos B_1, B_2, \dots, B_n es una partición finita de Ω si se cumplen las siguientes condiciones:

$$a) B_i \cap B_j = \emptyset, i \neq j, i, j = 1, 2, \dots, n. \quad (2.5)$$

$$b) B_i \cap B_j = \emptyset, i \neq j, i, j = 1, 2, \dots, n. \quad (2.6)$$

$$c) \bigcup_{i=1}^n B_i = \Omega. \quad (2.7)$$

Así, se requiere que cada uno de los elementos de una partición sea distinto del conjunto vacío, que sean ajenos dos a dos y que la unión de todos ellos constituya la totalidad del espacio muestral. De manera gráfica podemos representar una partición finita como se muestra en la Figura 2.2

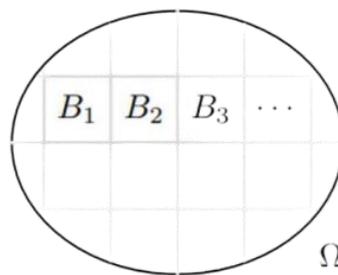


FIGURA 2.2: Teorema de probabilidad total. Figura tomada de [23]

2.2.4. Algoritmo de Naive Bayes para la clasificación

Es responsable de clasificar los documentos árabes dados a su clase de destino. Esto se realiza mediante el algoritmo Naive Bayes (NB). El clasificador NB calcula probabilidades de clases a posteriori, utilizando estimaciones obtenidas de un conjunto de entrenamiento de etiquetados documentos. Es el algoritmo más popular y más eficiente en el enfoque basado en árboles de decisión. Un algoritmo de árbol de decisión crea un modelo de árbol utilizando valores de un solo atributo a la vez. Al principio, el algoritmo ordena el conjunto de datos según el valor del atributo. Luego, busca regiones en el conjunto de datos que claramente contienen solo una clase y marcan esas regiones como hojas. Para las regiones restantes que tienen más de una clase, el algoritmo elige otro atributo y continúa el proceso de ramificación con solo el número de instancias en esas regiones hasta que produce todas las hojas o no hay ningún atributo que pueda usarse para producir una o más hojas. en las regiones en conflicto.

La idea detrás del algoritmo Naive Bayes es la probabilidad posterior de una instancia de datos t_i en una clase c_j del modelo de datos. La probabilidad posterior $P(t_i|c_j)$ es la posibilidad de que t_i pueda etiquetarse como c_j . $P(t_i|c_j)$ se puede calcular multiplicando todas las probabilidades de todos los atributos de la instancia de datos en el modelo de datos: con p denotado como el número de atributos en cada instancia de datos. La probabilidad posterior se calcula para todas las clases y la clase con mayor probabilidad será la etiqueta de la instancia. La clasificación (también conocida como árboles de clasificación o árboles de decisión) es un algoritmo de minería de datos que crea una guía paso a paso sobre cómo determinar la salida de una nueva instancia de datos. El árbol que crea es exactamente eso: un árbol en el que cada nodo en el árbol representa un lugar donde se debe tomar una decisión en función de la entrada, y pasamos al siguiente nodo y al siguiente hasta que llegamos a una hoja que te dice lo predicho producción.

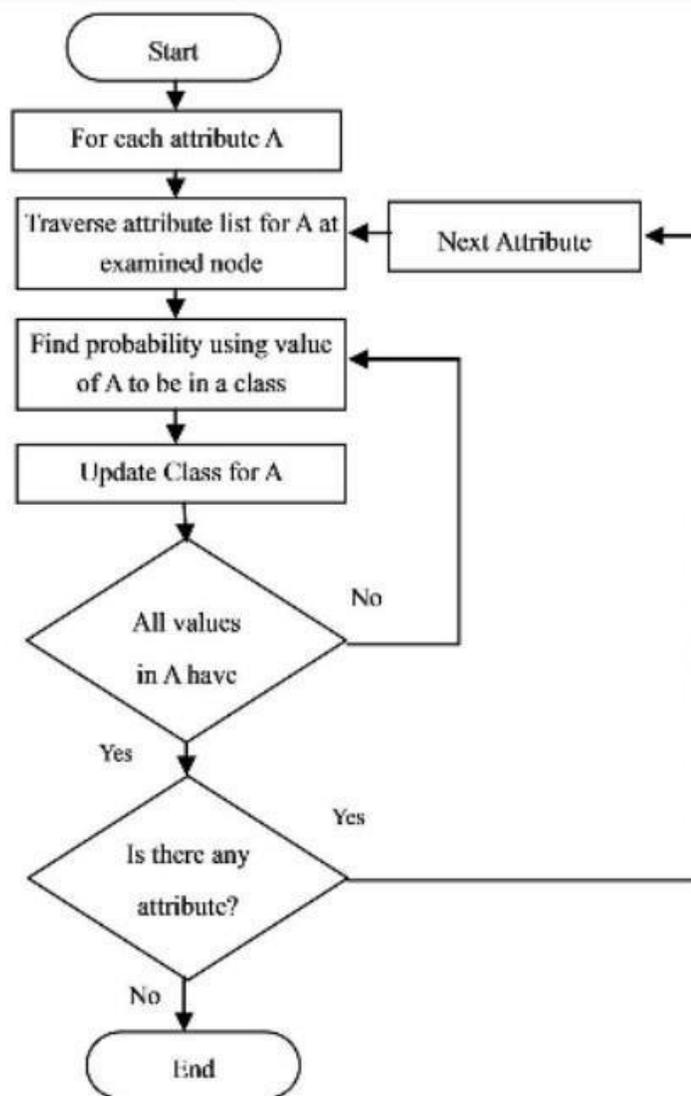


FIGURA 2.3: Algoritmo de clasificación Naive Bayes "Figura tomada de [4]"

El árbol de clasificación crea literalmente un árbol con ramas, nodos y hojas que nos permite tomar un punto de datos desconocido y movernos hacia abajo en el árbol, aplicando los atributos del punto de datos al árbol hasta que se alcanza una hoja y la salida desconocida de los datos. Se puede determinar el punto. Aprendimos que para crear un buen modelo de árbol de clasificación, necesitamos tener un conjunto de datos existente con una salida conocida a partir del cual podamos construir nuestro modelo. También dividimos nuestro conjunto de datos en dos partes: un conjunto de entrenamiento, que se usa para crear el modelo, y un conjunto de prueba, que se usa para verificar que el modelo es preciso y no está sobre ajustado.

2.2.5. Modelo bayesiano inicial

Vamos a presentar el modelo bayesiano propuesto en [10]. La diferencia de este modelo con respecto a otros enfoques es que no nos fuerza a decidir prematuramente qué píxeles están o no en una arista. Además, permitirá etiquetar posteriormente un píxel como perteneciente a una arista de los tres tipos que nos podemos encontrar en el mundo de Manhattan: i, j, k .

2.2.6. Redes Bayesianas

Las redes bayesianas (BN), también conocidas como redes de creencias (o redes bayesianas para abreviar), pertenecen a la familia de modelos gráficos probabilísticos (GM). Las estructuras gráficas se utilizan para representar el conocimiento sobre un dominio incierto. En particular, cada nodo en el gráfico representa una variable aleatoria, mientras que los bordes entre los nodos representan probabilidades dependencias entre las correspondientes variables aleatorias. Estas dependencias condicionales en el gráfico a menudo se estiman mediante el uso de estadísticas y Métodos computacionales. Por lo tanto, los BN combinan principios de la teoría de grafos, la teoría de la probabilidad, la computación ciencia y estadística. Los GM con bordes no dirigidos generalmente se denominan Campos aleatorios de Markov o redes de Markov. Estas Las redes proporcionan una definición simple de independencia entre dos nodos distintos basados en el concepto de una manta de Markov. Las redes de Markov son populares en campos como la física estadística y la visión artificial. Los BN corresponden a otra estructura GM conocida como un gráfico acíclico dirigido (DAG) que es popular en las estadísticas, el aprendizaje automático y el artificial sociedades de inteligencia. Los BN son matemáticamente rigurosa e intuitivamente comprensible. Ello permite

una representación y un cálculo efectivos de la distribución de probabilidad conjunta (JPD) sobre un conjunto de variables aleatorias. La estructura de un DAG está definida por dos conjuntos: el conjunto de nodos (vértices) y el conjunto de aristas dirigidas. Los nodos representan variables aleatorias y se dibujan como círculos etiquetados por los nombres de las variables. Los bordes representan dependencia directa entre las variables y se dibujan con flechas entre los nodos. En particular, un borde del nodo X_i al nodo X_j representa una estadística dependencia entre las variables correspondientes. Así, la flecha indica que un valor tomado por la variable X_j depende del valor que tome la variable X_i , o más o menos esa variable X_i "influye" X_j . Entonces se hace referencia al nodo X_i como un padre de X_j , de manera similar, X_j se conoce como el niño de X_i . Una extensión de estos términos genealógicos se utiliza a menudo para definir los conjuntos de "descendientes" El conjunto de nodos a los que se puede llegar de forma directa desde el nodo, o nodos "ancestros": el conjunto de nodos desde los que se puede llegar al nodo en un camino directo y la estructura del acíclico gráfico garantiza que no hay ningún nodo que pueda ser su propio antepasado o su propio descendiente. Tal condición es de vital importancia para la factorización de la probabilidad conjunta de una colección de nodos. Tenga en cuenta que aunque las flechas representan conexión causal directa entre las variables, el proceso de razonamiento puede operar en BNs propagando información en cualquier dirección. Un BN refleja una independencia condicional simple declaración. Esta propiedad se utiliza para reducir, a veces significativamente, el número de parámetros que se requieren para caracterizar el JPD de las variables. Esta reducción proporciona una manera eficiente para calcular las probabilidades posteriores dadas las evidencias. Además de la estructura DAG, que a menudo es considerada como la parte "cualitativa" del modelo, una necesita especificar los parámetros "cuantitativos" de la modelo. Los parámetros se describen de manera lo cual es consistente con una propiedad markoviana, donde la distribución de probabilidad condicional (CPD) en cada nodo depende sólo de sus padres. Para una variable aleatoria discreta, esta probabilidad condicional a menudo se representa mediante una tabla, que enumera la probabilidad local de que un nodo hijo toma cada uno de los valores factibles por cada combinación de valores de sus padres. La articulación la distribución de una colección de variables puede determinarse únicamente por estas probabilidades condicionales locales tablas (CPT) [22].

2.3. Redes neuronales

Existen numerosas formas de definir a las redes neuronales; desde las definiciones cortas y genéricas hasta las que intentan explicar más detalladamente qué son las redes neuronales. Por ejemplo:

1. Una nueva forma de computación, inspirada en modelos biológicos.
2. Un modelo matemático compuesto por un gran número de elementos procesales organizados en niveles.
3. Un sistema de computación compuesto por un gran número de elementos simples, elementos de procesos muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas.
4. Redes neuronales artificiales 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

Ventajas que ofrecen las red neuronal. Debido a su constitución y a sus fundamentos, las redes neuronales artificiales un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Entre las ventajas se incluyen:

- Aprendizaje Adaptativo. Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial
- Auto-organización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.
- Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.
- Operación en tiempo real. Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad

- Fácil inserción dentro de la tecnología existente. Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

2.3.1. Redes neuronales Artificiales y biológicas

Redes neuronales artificiales

Una red neuronal artificial (ANN) es un esquema de computación distribuida inspirada en la estructura del sistema nervioso de los seres humanos. La arquitectura de una red neuronal es formada conectando múltiples procesadores elementales, siendo éste un sistema adaptativo que posee un algoritmo para ajustar sus pesos (parámetros libres) para alcanzar los requerimientos de desempeño del problema basado en muestras representativas.

Por lo tanto podemos señalar que una ANN es un sistema de computación distribuida caracterizada por:

- Un conjunto de unidades elementales, cada una de las cuales posee bajas capacidades de procesamiento.
- Una densa estructura interconectada usando enlaces ponderados.
- Parámetros libres que deben ser ajustados para satisfacer los requerimientos de desempeño.
- Un alto grado de paralelismo.

Es importante señalar que la propiedad más importante de las redes neuronales artificiales es su capacidad de aprender a partir de un conjunto de patrones de entrenamientos, es decir, es capaz de encontrar un modelo que ajuste los datos. El proceso de aprendizaje también conocido como entrenamiento de la red puede ser supervisado o no supervisado. El aprendizaje supervisado consiste en entrenar la red a partir de un conjunto de datos o patrones de entrenamiento compuesto por patrones de entrada y salida. El objetivo del algoritmo de aprendizaje es ajustar los pesos de la red w de manera tal que la salida generada por la ANN sea lo más cercanamente posible a la verdadera salida dada una cierta entrada. Es decir, la red neuronal trata de encontrar un modelo al proceso desconocido que generó la salida. Este aprendizaje se llama supervisado pues se conoce el patrón de salida el cual hace el papel de supervisor de la red. En cambio, en el aprendizaje no supervisado se presenta sólo un conjunto de patrones a la ANN, y el objetivo del algoritmo de aprendizaje es ajustar los pesos de la red de manera tal que la red encuentre alguna estructura o configuración presente en los datos.

La Estructura de los modelos de ANN

Modelo de la Unidad de Procesamiento Elemental McCulloch and Pitts en 1943 concibieron un modelo abstracto y simple de una neurona artificial, este es el elemento básico de procesamiento en una red neuronal artificial. En la figura 2.4

2.3.2. Perceptrón

La arquitectura del perceptrón, llamada mapeo de patrones (pattern-mapping), aprende a clasificar modelos mediante un aprendizaje supervisado. Los modelos que clasifica suelen ser generalmente vectores con valores binarios (0,1) y las categorías de la clasificación se expresan mediante vectores binarios. El perceptrón presenta dos capas de unidades procesadoras (PE) y solo una de ellas presenta la capacidad de adaptar o modificar los pesos de las conexiones. La arquitectura del perceptrón admite capas adicionales pero estas no disponen la capacidad de modificar sus propias conexiones.

1. Inicializar pesos y parámetro de aprendizaje α (alpha)
2. Mientras no se cumpla la condición de paro debo hacer:
3. Para cada par de entrenamiento hacer pasos 4 y 6
4. Asignar activaciones de unidades de entrada
5. Calcular $Y_{in} = b + \sum X_i W_i$
6. Actualizar bias y pesos $i = 1. . . n$ Aplicar cuando rompe, la clase es incorrecta
 $w_i(new) := w_i(old) + \alpha(t - y_{in})X_i$ $t=target=$ clase ideal, a la que pertenece y Y_{in} lo que nos arrojó $b(new) := b(old) + \alpha(t - y_{in})$
7. Probar condición de paro

El entrenamiento del perceptrón consiste en presentar a la red todos los elementos del conjunto de entrenamiento constituido por parejas de vectores (entrada y salida deseada) de forma secuencial. El objetivo del entrenamiento es llegar a un conjunto de valores de los pesos de la red de forma que responda correctamente a todo el conjunto de entrenamiento. Después del entrenamiento los pesos no son ya modificados y la red está ya en disposición de responder adecuadamente a las entradas que se le presenten. La adaptación de los pesos se puede realizar mediante diferentes reglas.

Una de las reglas más simples de aprendizaje del perceptrón se indica en la ecuación:

$$W_{j_{nuevo}} = W_{j_{viejo}} + C(t_j * x_j)a_i$$

Siendo t_j el valor de la salida deseada, x_j el valor de salida producida por la unidad procesadora, a_i el valor de la entrada i y C el coeficiente de aprendizaje. En todo proceso de entrenamiento el comportamiento de la red inicialmente va mejorando hasta que llega a un punto en el que se estabiliza y se dice que la red ha convergido. Esta convergencia tiene dos posibilidades, la primera consiste en que la red haya aprendido correctamente el conjunto de entrenamiento y la segunda se trata de que la red no ha aprendido todas las respuestas correctas.

2.3.3. Algoritmo backpropagation

La invención del algoritmo Backpropagation ha desempeñado un papel vital en el resurgimiento del interés de las redes neuronales artificiales. Backpropagation es un método de entrenamiento de redes multicapa. Su potencia reside en su capacidad de entrenar capas ocultas y de este modo supera las posibilidades restringidas de las redes de una única capa. El concepto básico de Backpropagation fue presentado en 1974 por Paul Werbos [26] e independientemente reinventado por David Parker en 1982 [18], y también presentado en 1986 [18] por Rumelhart, Hinton y Willians. La duplicidad de esfuerzos y trabajos es frecuente en cualquier disciplina y más en el mundo de las ANN debido a su naturaleza interdisciplinaria

La unidad procesadora básica de la red Backpropagation se representa en la siguiente figura. Las entradas se muestran a la izquierda, y a la derecha se encuentran unidades que reciben la salida de la unidad procesadora situada en el centro de la figura. La unidad procesadora se caracteriza por realizar una suma ponderada de las entradas llamada S_j , presentar una salida a_j y tener un valor j asociado que se utilizará en el proceso de ajuste de los pesos. El peso asociado a la conexión desde la unidad i a la unidad j se representa por w_{ji} , y es modificado durante el proceso de aprendizaje.

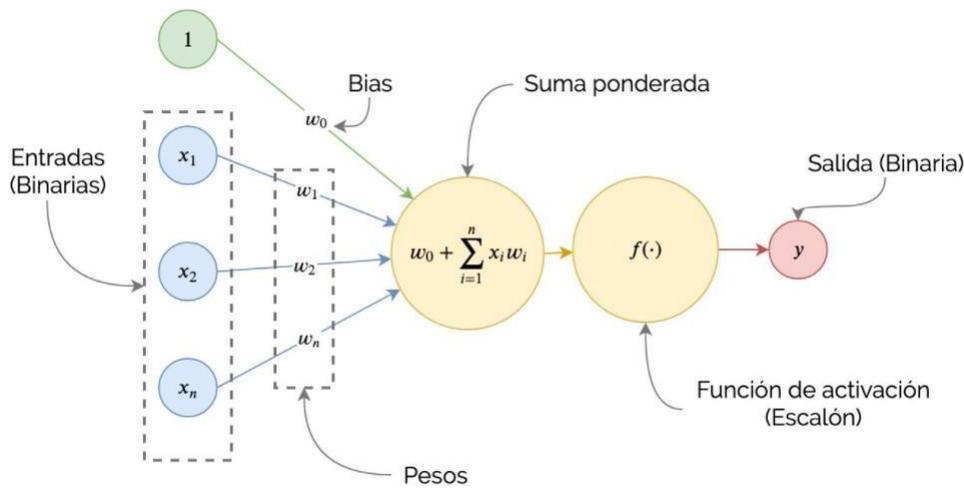


FIGURA 2.4: Algoritmo Backpropagation, Figura tomada de [1]

Normalmente, la Backpropagation utiliza tres o más capas de unidades procesadoras. La capa inferior es la capa de entrada, y se caracteriza por ser la única capa cuyas unidades procesadoras reciben entradas desde el exterior. Sirven como puntos distribuidores, no realizan ninguna operación de cálculo. Las unidades procesadoras de las demás capas procesan las señales. La siguiente capa superior es la capa oculta, y todas sus unidades procesadoras están interconectadas con la capa inferior y con la capa superior. La capa superior es la capa de salida que presenta la respuesta de la red. Convergencia: en el proceso de entrenamiento o aprendizaje de la Backpropagation es frecuente medir cuantitativamente el aprendizaje mediante el valor RMS (Root MeanSquare) del error de la red.

Esta medida refleja el modo en el que la red está logrando respuestas correctas; a medida que la red aprende, su valor RMS decrece. Debido a que los valores de salida de la red y los valores de salidas deseadas son valores reales, es necesario definir un parámetro de corte o un valor umbral del valor RMS del error de la red que permita decir que la red se aproxima a la salida deseada y considerar que la respuesta es correcta. La convergencia es un proceso en el que el valor RMS del error de la red tiende cada vez más al valor 0. La convergencia no siempre es fácil de conseguirla porque a veces el proceso puede requerir un tiempo excesivo o bien porque la red alcanza un mínimo local y deja de aprender.

TABLA 2.1: Comparación entre Perceptron y Backpropagation

Perceptron	Backpropagation
Clasificación Lineal	Clasificación No lineal
No tiene capas ocultas	Capas Ocultas
Solo propagación hacia adelante	Propagación hacia adelante y hacia atrás

2.3.4. Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN) son análogas a las ANN tradicionales en el sentido de que están compuestas por neuronas que se auto optimizan mediante el aprendizaje. Cada neurona seguirá recibiendo una entrada y realizará una operación (como un producto escalar seguido de una función no lineal), la base de innumerables ANN. Desde los vectores de imagen sin procesar de entrada hasta la salida final de la puntuación de la clase, toda la red seguirá expresando una única función de puntuación perceptiva (el peso). La última capa contendrá funciones de pérdida asociadas con las clases, y todavía se aplican todos los consejos y trucos habituales desarrollados para las ANN tradicionales.

La única diferencia notable entre las CNN y las ANN tradicionales es que las CNN se utilizan principalmente en el campo del reconocimiento de patrones dentro de imágenes. Esto nos permite a nosotros codificar características específicas de la imagen en

la arquitectura, haciendo que la red sea más adecuada para tareas centradas en imágenes, al tiempo que reduce aún más los parámetros necesarios para configurar el modelo.

Una de las mayores limitaciones de las formas tradicionales de ANN es que tienden a luchar con la complejidad computacional requerida para calcular datos de imágenes.

Conjuntos de datos comunes de evaluación comparativa de aprendizaje automático, como la base de datos MNIST de dígitos escritos a mano son adecuados para la mayoría de las formas de RNA, debido a su relativa dimensionalidad de imagen pequeña de solo 28×28 . Con este conjunto de datos, una sola neurona en la primera capa oculta contendrá 784 pesos ($28 \times 28 \times 1$ donde 1 tiene en cuenta que MNIST está normalizado a solo valores en blanco y negro), lo cual es manejable para la mayoría de las formas de ANN.

Entonces la CNN se enfocan principalmente en la base de que la entrada estará compuesta por imágenes. Esto enfoca la arquitectura que se configurará de la manera que mejor se adapte la necesidad de tratar con el tipo específico de datos.

Una de las diferencias clave es que las neuronas que forman las capas dentro de la CNN se componen de neuronas organizadas en tres dimensiones, la dimensionalidad espacial de la entrada (altura y el ancho) y la profundidad. La profundidad no se refiere al número total de capas dentro de la ANN, pero la tercera dimensión de un volumen de activación. A diferencia de ANNS estándar, las neuronas dentro de cualquier capa dada solo se conectarán a una pequeña región de la capa que la precede.

En la práctica, esto significaría que, para el ejemplo dado anteriormente, el 'volumen' de entrada tendrá una dimensionalidad de $64 \times 64 \times 3$ (altura, ancho y profundidad), lo que conduciría a una capa de salida final compuesta por una dimensionalidad de $1 \times 1 \times n$ (donde n representa el número posible de clases) ya que hubiéramos condensado la dimensionalidad de entrada completa en un volumen más pequeño de puntuaciones de clase archivadas en dimensión de profundidad.

Sigamos adelante con la derivación de las actualizaciones de retro propagación para capas convolucionales en una red. En una capa de convolución, los mapas de características de la capa anterior se convolucionan con kernels que se pueden aprender y pasar por la función de activación para formar el mapa de características de salida. Cada mapa de salida puede combinar convoluciones con múltiples mapas de entrada.

2.4. Extracción de Características

Al analizar los métodos de segmentación de texturas basados en características, es conveniente considerar por separado aquellos métodos que son interesantes principalmente debido a características únicas y aquellos que usan métodos únicos para realizar la segmentación. Refinando aún más estas categorías, muchas características pueden considerarse derivadas de operadores, de pruebas estadísticas o del examen de la imagen en un dominio de transformación.

Las técnicas de reducción de dimensionalidad se han convertido en una necesidad obvia en el campo médico (aplicación automatizada). Hoy por hoy se genera una gran cantidad de datos en el dominio médico. Este incluye los síntomas que un paciente puede tener y también muchos informes de pruebas médicas que se puedan generar. La característica es sinónimo de variables de entrada y atributos. En medicina ejemplo de diagnóstico, las características pueden ser síntomas, consisten en un conjunto de variables que clasifican el estado de salud de un paciente (por ejemplo, en Síntomas de retinopatía diabética de Seco o Húmedo Relacionados con la edad degeneración macular (AMD)). En esta sección revisión de la literatura de algunos métodos de selección y extracción de características ampliamente utilizados. Los métodos en la detección y diagnóstico de muchas enfermedades oculares para oftalmólogos (glaucoma, retinopatía diabética y especialmente para la detección automática de macular relacionado con la edad degeneración). El objetivo principal de esta revisión es sensibilizar a los profesionales sobre los beneficios y, en algunos casos, incluso la necesidad de aplicar reducción de dimensionalidad mediante técnicas para beneficiarse de la reducción de la dimensionalidad técnicas con el fin de maximizar la precisión del aprendizaje algorítmico, es necesario tener conocimiento de varias ventajas de estas técnicas. A continuación se enumeran las siguientes ventajas de la selección de funciones:

- Reduce la dimensionalidad del espacio de características, para limitar los requisitos de almacenamiento y aumentar el algoritmo velocidad.
- Elimina los datos redundantes, irrelevantes o ruidosos.
- Los efectos inmediatos para las tareas de análisis de datos son acelerar el tiempo de ejecución del aprendizaje algoritmos.
- Mejorar la calidad de los datos.
- Aumentar la precisión del modelo resultante.
- Reducción del conjunto de características, para ahorrar recursos en la próxima ronda de recopilación de datos o durante la utilización.
- Mejora del rendimiento, para ganar en predictiva precisión.
- Comprensión de datos para obtener conocimiento sobre el proceso que generó los datos o simplemente visualiza el dato.

P. Soliz et al. [30] ha propuesto un enfoque para la extracción de características basadas en imágenes para clasificar la AMD en imágenes retinianas digitales. Un oftalmólogo ha clasificado 100 imágenes en 12 categorías basadas en las características visuales de la enfermedad. El análisis de componentes independientes (ICA) se ha utilizado para extraer características y se ha utilizado como entrada para el clasificador. Se ha demostrado que el ICA puede detectar y caracterizar las características de las imágenes de fondo y extraer implícitamente las características matemáticas de cada imagen para definir el fenotipo. M. Pechenizky [34] ha analizado los efectos del ruido de clase (clasificación errónea o etiquetado incorrecto) en el aprendizaje supervisado en dominios médicos. Se ha discutido una revisión del trabajo relacionado sobre el aprendizaje de los datos ruidosos y se ha propuesto utilizar la extracción de características como un paso de preprocesamiento para disminuir el efecto del ruido de clase en el proceso de aprendizaje. Muchos de estos enfoques de filtrado se han resumido y se han reconocido como útiles por los investigadores. Sin embargo, los mismos investigadores han reconocido algunas dificultades prácticas con los enfoques de filtrado. Otra preocupación es que una técnica de filtrado puede utilizar un nivel esperado de ruido como un parámetro de entrada, y este valor rara vez se conoce para un conjunto de datos en particular. La extracción de características se adapta mejor a las técnicas tolerantes al ruido, ya que ayuda a evitar el sobreajuste implícito dentro de las técnicas de aprendizaje. La extracción de características antes de emprender el aprendizaje supervisado permite disminuir los efectos negativos de la presencia de instancias mal etiquetadas en los datos. En el método de detección de diabéticos utilizando ANN y un conjunto de características formado por la adopción de la descomposición en valores singulares (SVD) y el análisis de componentes principales (PCA) se ha propuesto. Los resultados

experimentales muestran que la composición ANN-SVD+PCA es un medio confiable de detección de la diabetes con menos costo computacional y alta precisión. Los métodos de extracción de características se han encontrado mucho más adecuados para la detección automatizada de enfermedades oftalmológicas que los métodos de selección de características debido a los datos ruidosos. Debido a que la mayoría de los conjuntos de datos relacionados con la biomedicina contienen datos ruidosos en lugar de datos irrelevantes o redundantes.

2.4.1. Técnicas de Extracción de Características

La extracción de características es la más importante y sensible. La precisión del sistema depende principalmente de la calidad de la función. Se utilizan diferentes técnicas automatizadas de extracción de características para hacer que el proceso de detección de glaucoma sea más confiable y exitoso. Muestra diferentes técnicas de extracción de características utilizadas en el proceso de detección de glaucoma. El enfoque del método In Moment se utilizó para detectar características como la mediana, la media y la varianza. En diferentes métodos de extracción, incluidos el valor de intensidad de píxeles, las texturas, los coeficientes de la Transformada rápida de Fourier (FFT), la intensidad de píxeles y el modelo de histograma se utilizaron para identificar características como la luminancia, la invariancia de traducción, el borde de la papila y el tamaño de la copa. El método de umbral de mosaico se usó para identificar características como el color y la forma. En Macular Cube, se usó el algoritmo para extraer características como el grosor de la mácula. Se usaron módulos de método de pintura secuencial diseñados para identificar características como la relación entre la copa y el disco, la configuración del borde neuroretiniano, la información de distribución de los vasos en un sistema automático de análisis de imágenes de fondo de ojo para el diagnóstico clínico del glaucoma.

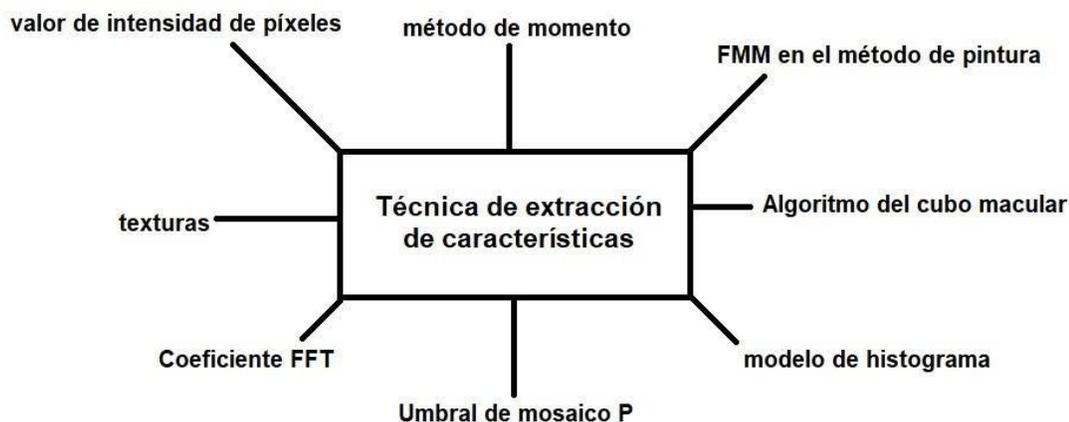


FIGURA 2.5: Técnicas de extracción de características utilizadas en la detección de glaucoma. Figura "Tomada de [16]"

2.4.2. Técnicas de Selección de Características

La selección de características es el proceso de seleccionar un subconjunto de características relevantes para su uso en la construcción del modelo. Representa diferentes técnicas de selección de características utilizadas en la detección de glaucoma. En la prueba de hipótesis de suma de rangos de Wilcoxon, se utilizó la técnica de selección de características para detectar 50 y 34 de 508 dimensiones. Se usó la técnica de análisis de componentes principales (PCA) para identificar 30 de 970 dimensiones. Se usaron envoltorios y filtros para identificar 29 de 254 dimensiones.

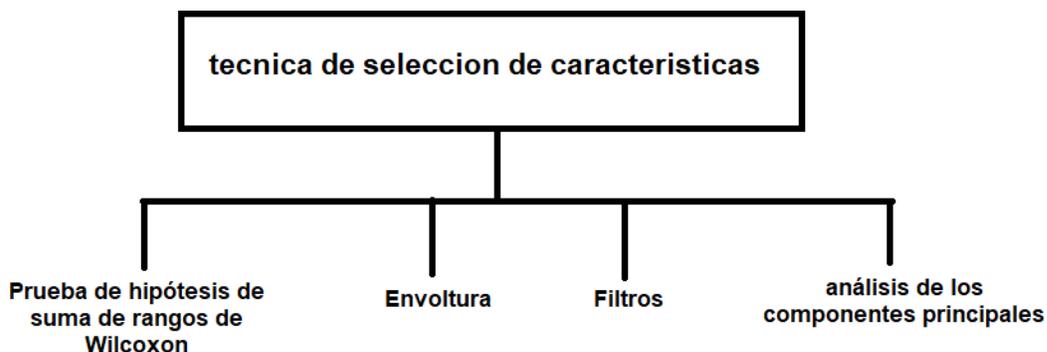


FIGURA 2.6: Técnicas de extracción de características utilizadas en la detección de glaucoma. Figura "tomada de [16]"

2.4.3. Técnicas de Aprendizaje Automático

La detección automática de glaucoma se ha logrado mediante diferentes técnicas de Machine Learning (ML). La tabla 2 muestra diferentes técnicas de ML utilizadas para predecir y detectar el glaucoma. En redes neuronales se utilizó para la detección y a la lógica difusa para la predicción del glaucoma. Se utilizó un árbol de decisión basado en algoritmos ID3 para la actividad de detección de glaucoma y se logró una precisión del 85%. In Vector Support Machine se utilizó para la clasificación de glaucoma y logró una precisión del 80%. Se utilizaron el clasificador Naive Bayes y el vecino más cercano k y la precisión resultante fue del 86%. El detector de bordes Canny, un modelo de contorno activo logró un total del 50% de precisión, la regresión lineal logró una precisión del 99% en la detección de glaucoma y del 14% en la predicción del glaucoma. La red neuronal difusa min-max fue capaz de lograr una precisión del 97%.

<u>Machine Learning Techniques</u>	<u>Glaucoma Detection</u>	<u>Glaucoma Prediction</u>
ID3 algorithm for decision tree	✓	
Accuracy	85%	
Fuzzy Logic		✓
Neural Network	✓	
Naive Bayes classifier	✓	
Accuracy	86%	
k- nearest neighbor	✓	
Accuracy	86%	
Canny Edge detector	✓	
Linear regression	✓	✓
Accuracy	99%	14%
Fuzzy min-max neural network based on Data-Core (DCFMN)	✓	
Accuracy	97%	
active contour model algorithm	✓	
Accuracy	50%	
Support Vector Machine	✓	
Accuracy	80%	

TÉCNICAS DE APRENDIZAJE AUTOMÁTICO UTILIZADAS EN DETECCIÓN PREDICCIÓN DE GLAUCOMA. Tabla "Tomada de [16] "

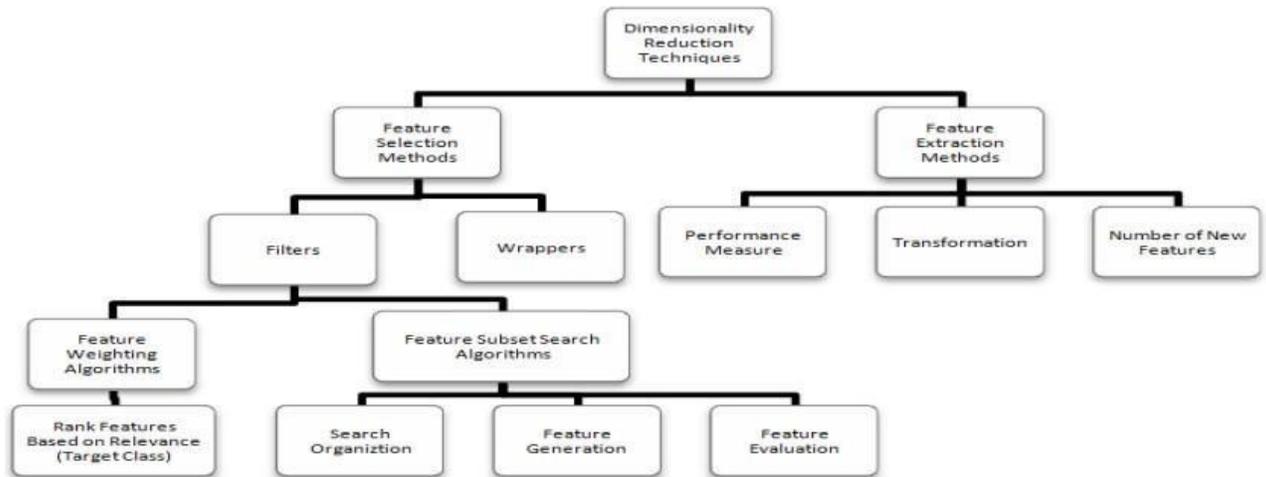
2.4.4. Enfoques de Reducción de Dimensionalidad

Los datos de alta dimensionalidad presentan problemas para la clasificación. Esto hace que los algoritmos sean costosos computacionalmente y que requieran una gran cantidad de memoria. Existen dos técnicas de reducción de dimensionalidad conocidas como extracción de características (también llamada reducción de dimensionalidad explícitamente o transformación de características) y selección de características. (FS) [36].

Selección de características

Los datos de alta dimensión pueden contener características irrelevantes, engañosas o redundantes que dificultan el procesamiento de datos y no contribuyen al aprendizaje. La selección de características es el proceso de elegir las mejores características útiles para discriminar clases. Los algoritmos de selección de características se caracterizan por ser una búsqueda de acuerdo con ciertos criterios de evaluación. Ladha et al han presentado una comparación empírica de diferentes algoritmos de selección de características. (FSA) es un modelo computacional que es provocado por una cierta definición de relevancia. Ladha et al se han presentado una comparación empírica de diferentes características de selección algoritmos En general, la selección de funciones se conoce como búsqueda problema ,de acuerdo con algunos criterios de evaluación . Selección de características; los algoritmos se pueden caracterizar por:

1. La organización de búsqueda puede ser exponencial, secuencial o aleatoria.
2. La generación de subconjuntos puede ser realizada a través de cinco operadores diferentes: Adelante, Atrás, Compuesto, Ponderado y Aleatorio.
3. La medida de evaluación de los sucesores puede ser llevada a cabo a través de diversas técnicas, tales como: Probabilidad de Error, Divergencia, Dependencia, Distancia Intercalase, Información o Incertidumbre y Consistencia Evaluación, como se muestra en la Figura a continuación.



Estructura jerárquica de los enfoques de reducción de la dimensionalidad. Figura tomada de [9]

Los métodos de selección de características se pueden distinguir en tres categorías:

- Filtros
- Contenedores
- Método integrado/híbrido

Los métodos de envoltorio funcionan mejor que los métodos de filtro porque el proceso de selección de características está optimizado para que el clasificador sea más útil. Sin embargo, los métodos de envoltorio son costosos en términos computacionales y cada conjunto de características debe evaluarse con el clasificador entrenado, lo que hace que el proceso de selección de funciones sea lento. Por otro lado, los métodos de filtro tienen un costo computacional más bajo y son más rápidos, pero su confiabilidad en la clasificación es menos eficiente en comparación con los métodos de envoltura, y son más adecuados para conjuntos de datos de alta dimensión. Recientemente se han desarrollado enfoques híbridos/integrados que aprovechan las ventajas de ambos enfoques de filtro y envoltura. Un enfoque híbrido utiliza tanto una prueba independiente como una función de evaluación del desempeño del subconjunto de características. Los métodos de filtro se pueden clasificar en dos grupos, a saber, algoritmos de ponderación de características y algoritmos de búsqueda de subconjuntos. Los algoritmos de ponderación de características asignan pesos a las características individualmente y las clasifican en función de su relevancia para el concepto objetivo. Un conocido algoritmo que se basa en la evaluación de relevancia es Alivio.

Extracción/Transformación de características

La extracción de características implica alguna transformación de las características originales para generar otras características más importantes. Brian Ripley definió la extracción de características de la siguiente manera: "La extracción de características se utiliza generalmente para referirse a la construcción de combinaciones lineales Tx de características continuas que tienen un buen poder discriminatorio entre clases". Un problema importante en la investigación de redes neuronales y otras disciplinas de inteligencia artificial es la búsqueda de una representación adecuada de datos multivariados. La extracción de características se puede utilizar en este contexto para reducir la complejidad y proporcionar una representación simple de los datos mediante la representación de cada variable en el espacio de características como una combinación lineal de la variable de entrada original.

El enfoque de extracción de características más popular y ampliamente utilizado es el Análisis de Componentes Principales (PCA), introducido por Karl. Se han probado empíricamente diferentes métodos de reducción de dimensionalidad (incluyendo el subconjunto de características utilizando métodos de selección de ganancia de información (IG) y envoltura, y extracción de características con diferentes sabores de métodos PCA) y los efectos de estos métodos en el rendimiento de la clasificación en dos tipos diferentes de conjuntos de datos (datos de correo electrónico y datos de descubrimiento de fármacos). [14].

Análisis De La Selección De Diferentes Características Y Técnicas De Extracción De Características

Algoritmos de selección de características (FSA): una descripción general de algunas FSA básicas tienen más pruebas estadísticas de uso común que miden la divergencia de la distribución esperada si se supone que la ocurrencia de la característica es realmente independiente de los valores de clase. La distancia euclidiana examina la raíz de las diferencias cuadradas entre las coordenadas de un par de objetos. La ventaja de este método es que la distancia no se ve afectada por la adición de nuevos objetos al análisis, lo que puede ser útil para identificar valores atípicos. Sin embargo, la distancia euclidiana puede verse muy afectada por las diferencias de escala entre las dimensiones a partir de las cuales se calcula la distancia. La prueba evalúa si el promedio de dos grupos es estadísticamente diferente uno del otro. Este análisis se utiliza siempre que hay necesidad de comparar el promedio de dos grupos y es especialmente adecuado como análisis para el diseño

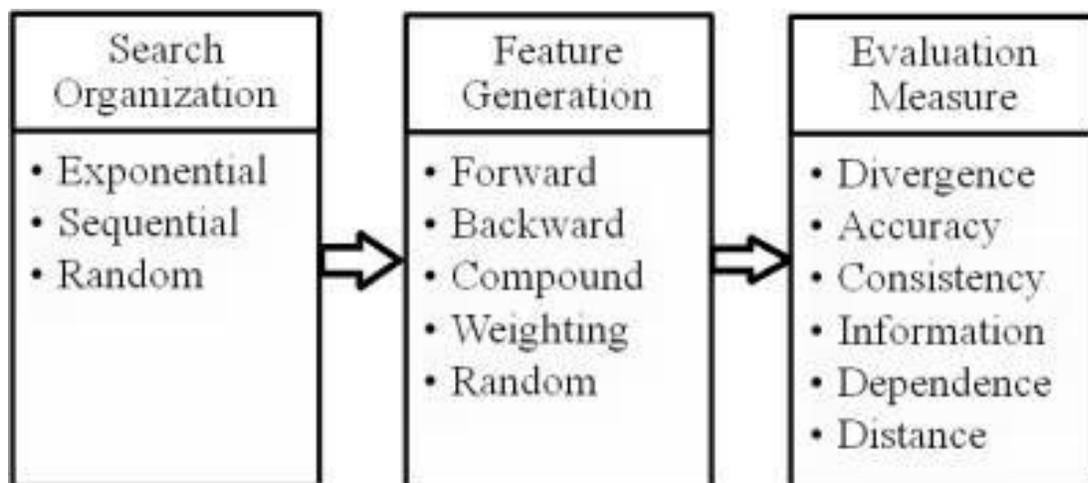
experimental aleatorizado de dos grupos solo después de la prueba. Ganancia de información (IG) mide el aumento de entropía cuando se da la característica vs ausente. Esta es la aplicación de técnicas más generales, la medición de la entropía informacional, al problema de decidir qué tan importante es una característica dentro del espacio de características. Función de búsqueda de selección de características basada en correlación (CFS) subconjunto según el grado de redundancia entre los características. El proceso de evaluación tiene como objetivo encontrar subconjuntos de características que están individualmente altamente correlacionados con la clase pero tienen baja intercorrelación. La relevancia del grupo de características crece con la correlación entre características y clase, y disminuye con creciente intercorrelación. CFS se utiliza para determinar la mejor subconjunto de características y generalmente se combina con estrategias de búsqueda tales como; selección hacia adelante, eliminación hacia atrás, bidireccional búsqueda, mejor primera búsqueda y búsqueda genética. Lei Yo et al, introdujeron un concepto novedoso, correlación predominante, y propuso un método de filtro rápido que puede identificar características relevantes, así como la redundancia entre características relevantes sin análisis de correlación por pares. La selección directa secuencial (SFS) es la búsqueda codiciosa más simple algoritmo. SFS funciona mejor cuando el subconjunto óptimo tiene un pequeño número de características. La principal desventaja de SFS es que no puede eliminar funciones que quedan obsoletas después de la adición de otras características. Eliminación secuencial hacia atrás (SBE) trabaja en dirección opuesta a SFS. SBE funciona mejor cuando el subconjunto de características tiene una gran cantidad de características. El problema con los algoritmos de selección de características individuales es que solo capturan la relevancia de las características para el concepto de destino y evitar la redundancia entre características. Evidencia empírica de la literatura de selección de características muestra que, junto con funciones, las funciones redundantes también afectan la velocidad y la precisión de algoritmos de aprendizaje y, por lo tanto, también deben eliminarse. En el contexto de la selección de características para alta datos dimensionales donde pueden existir muchos datos redundantes características, los algoritmos de ponderación de características basados en la relevancia pura hacen no satisfacer muy bien la necesidad de selección de funciones. Selección de subconjuntos de características. El algoritmo de búsqueda de subconjuntos de características busca características candidatas para subconjuntos guiados por alguna métrica de evaluación, capturando la bondad de cada subconjunto.

Se deben considerar los siguientes aspectos en el proceso de selección de características:

1. Punto de partida,
2. Buscar Estrategia,
3. Evaluación de subconjuntos,
4. Criterios de parada.

Sobre la base de estos aspectos, un análisis comparativo de las técnicas de selección de características se muestra en la siguiente imagen.

Caracterizamos técnicas de selección de características de manera que podamos dar una visión general y comparativa sobre la organización de la búsqueda, la generación de características y la evaluación de cada técnica de selección de características. Esto puede guiar la elección de una técnica adecuada a los objetivos y recursos de los profesionales en el campo. [8].



Caracterización de algoritmos de selección de características. Figura tomada de [15]

2.4.5. Métodos de extracción que usa como base el método bayesiano.

Methods	Individual / Subset Feature	Starting Point	Search Strategy	Subset Generation	Subset Evaluation	Stopping Criteria	Used to Eliminate
Correlation Coefficient	Individual	Random Number of Features	Sequential	Forward Selection	Divergence (variance)	Ranking	Irrelevant Features
BW-ration	Individual	Full Feature Set	Sequential	-	Divergence (variance)	Ranking	Irrelevant Features
PAM	Individual	Random Number of Features	Sequential	Weighted	Distance/Information	Ranking	Irrelevant Features
mRmR	Subset	Random Number of Features	Random	Forward Selection	Mutual dependence/information	Ranking	Redundant Features / Irrelevant Features
I-RELIEF	Subset	Random Number of Features	Random	Weighted	Distance	Ranking	Irrelevant Features
CMIM	Subset	Full Feature Set	Sequential	Forward Selection	Conditional Mutual Information /	Relevance	Irrelevant Features
INTERACT	Subset	Full Feature Set	Sequential	Backward Elimination	Consistency	Relevance	Irrelevant Features
Genetic Algorithm	Subset	Full Feature Set	Random	Weighted	Consistency (cosine)	Ranking	Redundant Features / Noise
SVM-REF	Subset	Full Feature Set	Sequential	Backward Elimination/Weighted	Information	Ranking	Irrelevant Feature

ANÁLISIS COMPARATIVO DE ALGORITMOS DE SELECCIÓN DE CARACTERÍSTICAS. Tabla tomada de [15]

Para evaluar las técnicas de selección de subconjuntos de características, se han utilizado dos algoritmos de aprendizaje: Naive Bayes y LIBSVM. Casi todas las técnicas mencionadas anteriormente funcionaron bien en esta evaluación.

2.4.6. Detección de puntos característicos.

Las características se utilizan para construir clasificadores y, como resultado, se operan en dimensiones altas. El proceso de aprendizaje se vuelve complejo, lo que a su vez conduce a un alto error de clasificación. Por lo tanto, es necesario reducir la dimensionalidad del espacio de características antes de la clasificación.

El objetivo principal de DR es transformar las muestras de datos de alta dimensión en las de baja dimensión, de tal manera que se conserve la información intrínseca contenida en los datos. Una vez que la dimensionalidad se reduce, se ayuda a mejorar la robustez del clasificador y se reduce la complejidad computacional. Según la estrategia adoptada, las técnicas de reducción de dimensionalidad se dividen en selección de características y extracción de características. [27].

Una imagen integrada deberá contener una gran cantidad de datos que en su mayoría proporcionan muy poca información para que se pueda interpretar. Un sistema que incorpore una visión deberá, en primer lugar, extraer de manera eficaz y robusta ciertas características que proporcionen la máxima información posible. Estas características deberán cumplir, entre otras, las siguientes condiciones:

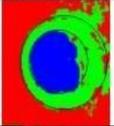
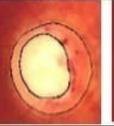
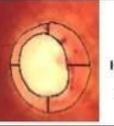
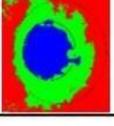
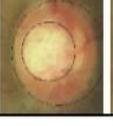
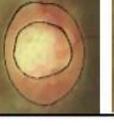
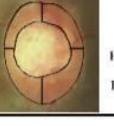
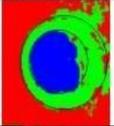
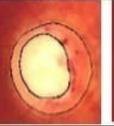
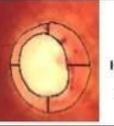
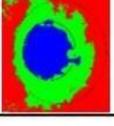
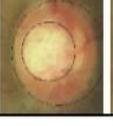
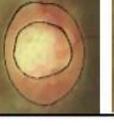
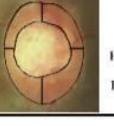
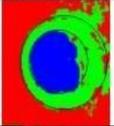
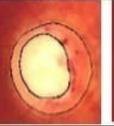
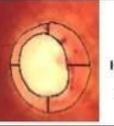
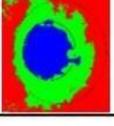
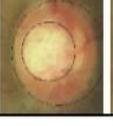
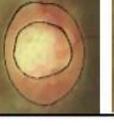
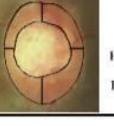
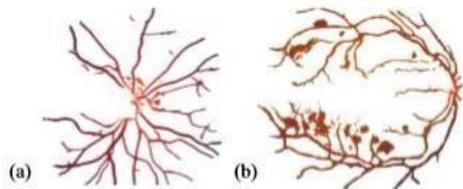
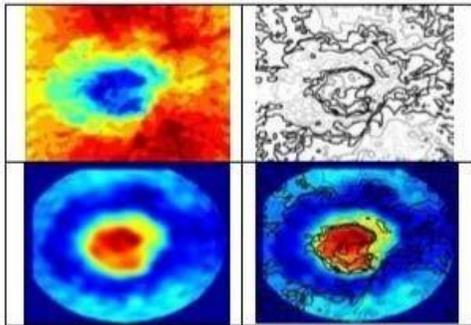
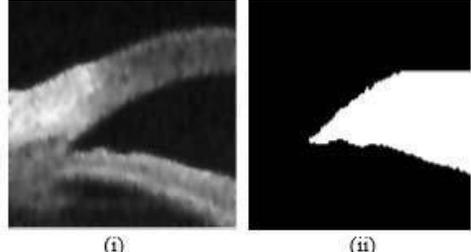
- Su extracción a partir de la imagen no debe suponer un coste excesivo al sistema en el cual está integrado. El tiempo total de extracción debe ser lo más pequeño posible.
- Su localización debe ser muy precisa. El error cometido en la estimación de las características también debe ser lo más pequeño posible.
- Deben ser robustas y estables. Deberían permanecer a lo largo de una secuencia.
- Contendrán la máxima información posible de la escena, es decir, debemos ser capaces de extraer información de tipo geométrico a partir de ellas

Las aristas, esquinas y puntos de intersección satisfacen estas condiciones. Aparecen de forma natural en la mayoría de escenarios, tanto naturales como artificiales (construidos por el hombre). Sin embargo, la obtención de las aristas suele ser una fuente de muchos errores. Por ejemplo, consideremos el algoritmo de detección de aristas más comúnmente utilizado, el algoritmo de Canny [Canny, 1986]. Este algoritmo combina un operador diferencial con un filtro gaussiano y funciona.

1. Reduciendo el ruido
2. Cálculo de gradientes
3. Supresión no máxima
4. Doble umbral
5. Seguimiento de borde por histéresis.

Variando el parámetro de varianza del filtro utilizado por el algoritmo de Canny, podemos observar diferentes comportamientos (ver figura emma): al disminuir la varianza, aparecen muchas aristas, pero la mayoría de ellas no proporcionan información valiosa. Sin embargo, la localización de las aristas es precisa. Al aumentar la varianza, solo se detectan las aristas que se encuentran en zonas de alto contraste, pero la localización no es tan exacta y el tiempo de procesamiento aumenta. Este comportamiento también ocurre en la mayoría de los filtros de detección de aristas. Además, el uso de derivadas de la imagen para calcular aristas puede introducir errores debido al ruido de la captación de la imagen, según el trabajo de Micheli et al. (1989). Una unión es la intersección de dos o más aristas en un punto de la imagen. Es importante distinguir entre una unión y un punto de esquina o punto característico (los términos se utilizan indistintamente). Un punto de esquina es un punto en la imagen donde el contorno de una arista tiene curvatura alta y/o el centro de una unión. Desde el punto de vista computacional, se han propuesto dos enfoques principales para detectar estas características bidimensionales:

1. Métodos que obtienen las aristas de la imagen mediante algún método de detección de aristas como el de Canny, para, a continuación detectar puntos de cruce entre aristas o con un cambio sustancial en la dirección de la arista. Estos puntos se clasifican como puntos esquina o unión.
2. El resto de métodos trabajan directamente sobre imágenes de gris, es decir, no se infieren a partir de la extracción de aristas.

Característica de detección referencial	Imágenes ejemplares																		
<p>Relación de disco a copa</p>	<table border="1"> <thead> <tr> <th>Fundus retinal image</th> <th>Extracted and segmented regions with fitted circles</th> <th>Detected cup and disc regions (without vessels)</th> <th>Cup and disk boundaries after ACM detection</th> <th>ISNT analysis</th> <th>Diagnosis Results</th> </tr> </thead> <tbody> <tr> <td></td> <td></td> <td></td> <td></td> <td></td> <td> <p>Glaucoma</p> <p>CDR(circle) = 0.68 Horizontal CDR(ACM) = 0.60 Vertical CDR(ACM) = 0.68 I:0.15 S:0.13 N:0.28 T:0.11 Violate ISNT rules</p> </td> </tr> <tr> <td></td> <td></td> <td></td> <td></td> <td></td> <td> <p>Normal</p> <p>CDR(circle) = 0.56 Horizontal CDR(ACM) = 0.68 Vertical CDR(ACM) = 0.54 I:0.27 S:0.18 N:0.16 T:0.12 Obey ISNT rules</p> </td> </tr> </tbody> </table>	Fundus retinal image	Extracted and segmented regions with fitted circles	Detected cup and disc regions (without vessels)	Cup and disk boundaries after ACM detection	ISNT analysis	Diagnosis Results						<p>Glaucoma</p> <p>CDR(circle) = 0.68 Horizontal CDR(ACM) = 0.60 Vertical CDR(ACM) = 0.68 I:0.15 S:0.13 N:0.28 T:0.11 Violate ISNT rules</p>						<p>Normal</p> <p>CDR(circle) = 0.56 Horizontal CDR(ACM) = 0.68 Vertical CDR(ACM) = 0.54 I:0.27 S:0.18 N:0.16 T:0.12 Obey ISNT rules</p>
Fundus retinal image	Extracted and segmented regions with fitted circles	Detected cup and disc regions (without vessels)	Cup and disk boundaries after ACM detection	ISNT analysis	Diagnosis Results														
					<p>Glaucoma</p> <p>CDR(circle) = 0.68 Horizontal CDR(ACM) = 0.60 Vertical CDR(ACM) = 0.68 I:0.15 S:0.13 N:0.28 T:0.11 Violate ISNT rules</p>														
					<p>Normal</p> <p>CDR(circle) = 0.56 Horizontal CDR(ACM) = 0.68 Vertical CDR(ACM) = 0.54 I:0.27 S:0.18 N:0.16 T:0.12 Obey ISNT rules</p>														
<p>Vaso sanguíneo retinal</p> <ul style="list-style-type: none"> ■ (a) Normal ■ (b) desertado 																			
<p>Estructura del disco óptico</p>																			
<p>Arco de ángulo</p> <ul style="list-style-type: none"> ■ (i) Preprocesado ■ (ii) Segmentado 																			

IMÁGENES DE EJEMPLO PARA CARACTERÍSTICAS DE DETECCIÓN REFERENCIAL

Capítulo 3

Antecedentes

3.1. Modelado del Glaucoma y Diagnóstico asistido por Red Neuronal

La visión es el sentido más importante para los seres humanos. El ojo humano puede considerarse una estructura esférica con un radio de unos 12 mm. El interior del ojo está lleno de una sustancia transparente llamada corpus vítreo. La retina cubre la superficie interior y contiene fibras nerviosas ópticamente sensibles que recogen las señales ópticas. Estas fibras salen del ojo a través del disco óptico, también conocido como el punto ciego. Si la presión interna del ojo aumenta o si el suministro de sangre al disco óptico o a la retina disminuye, puede haber una degeneración de las fibras nerviosas y aparecer defectos en el campo visual. Dado que el sistema visual humano puede compensar en parte la falta de visión en el campo, el aumento de la presión puede pasar desapercibido más allá del límite donde los cambios inducidos son reversibles. Los cambios patológicos son colectivamente llamados glaucoma de ángulo abierto primario (GPAA). El diagnóstico precoz es fundamental para preservar una buena función visual, ya que si no se trata, el POAG puede conducir a la ceguera dentro de cinco a diez años. El GPAA es un diagnóstico bastante común en Dinamarca, afectando aproximadamente al 2 % de la población, en su mayoría ancianos. Alrededor del 5 % de los diagnosticados eventualmente terminan ciegos. En este proyecto, el objetivo es desarrollar herramientas para el diagnóstico precoz del GPAA basado en las llamadas imágenes de fondo de ojo, es decir, imágenes de la retina tomadas a través de la pupila con un sistema de cámara dedicado. En primer lugar, se ha desarrollado un modelo para el modelado de los cambios en la retina inducidos por el Glaucoma. Este modelo puede ser utilizado para la formación de médicos y, como en este estudio, para experimentos controlados con dispositivos de reconocimiento de patrones. Se espera que el uso de herramientas de diagnóstico precisas y tempranas pueda prevenir o retrasar la pérdida de la visión en pacientes con GPAA.

Este modelo puede ser utilizado para la formación de médicos, y como en este estudio, un laboratorio para experimentos controlados con dispositivos de reconocimiento de patrones. En segundo lugar, tenemos desarrollado un esquema de pre-procesamiento y redes neuronales celulares para la detección del patrón de fibra nerviosa como se ve en las imágenes de fondo de ojo, para más detalles ver un estudio de análisis de imágenes para la detección de glaucoma fue llevado a cabo por Yamazaki et al. En esta investigación el diagnóstico se basa en un análisis de un solo perfil de intensidad aproximadamente ortogonal a la línea que conecta el disco óptico y el punto de fijación. En nuestro experimento este esquema tiene demostrado no ser robusto a las variaciones en la calidad de imagen del fondo de ojo estándar fotos.

3.1.1. Modelado De Cuadros De Fondo Y Glaucoma

El modelo paramétrico de imágenes de fondo de ojo se ha creado con el objetivo de proporcionar una herramienta para comparar diferentes algoritmos informáticos para el diagnóstico y mejora del glaucoma. El modelo se ha basado en el análisis de imágenes de fondo de ojo originales y se han identificado las características más prominentes de la escena, como los vasos sanguíneos, la macula y las fibras nerviosas que forman una textura de patrón de líneas. El glaucoma inducido por la pérdida de fibras nerviosas puede tomar dos formas diferentes: una reducción uniforme de la densidad de las fibras o una característica desaparición regional (en cuña) de las fibras. La creación de este modelo proporciona una herramienta valiosa para la formación de médicos y para experimentos controlados con dispositivos de reconocimiento de patrones.

3.1.2. Imágenes De Fondo Artificial

Entonces, el modelo de imagen consta de dos módulos: el módulo de diseño de vasos sanguíneos, que permite crear un diseño semirrealista de vasos sanguíneos con diámetro variable y alisado del borde del vaso y, el generador de fibras nerviosas, que dibuja patrones de líneas de curvas paramétricas de segundo orden en 36 sectores alrededor del disco óptico, con la orientación definida por el disco óptico y el punto de fijación. La relación señal a ruido se puede controlar para proporcionar una apariencia realista de la textura. La matriz resultante de estos módulos contiene las ubicaciones predefinidas del disco óptico y del punto de fijación, así como las características agregadas de los vasos sanguíneos y las fibras nerviosas. Este modelo se utiliza como base para la comparación de algoritmos informáticos para la mejora y el diagnóstico del glaucoma.

3.1.3. Pre procesamiento

Después de la eliminación de los artefactos de iluminación y del sistema de vasos sanguíneos, el siguiente paso en el pre procesamiento de una imagen de fondo de ojo es la corrección de la distorsión geométrica de la imagen. Esto se hace utilizando técnicas de corrección geométrica, como la corrección de la distorsión esférica o la corrección de la distorsión de barril.

Una vez corregida la distorsión geométrica, se pueden aplicar técnicas de filtrado para mejorar la calidad de la imagen. El filtrado se utiliza para reducir el ruido y mejorar la definición de los bordes de los objetos en la imagen.

Finalmente, se pueden aplicar técnicas de segmentación para identificar regiones de interés en la imagen, como el disco óptico y la mácula. La segmentación se realiza utilizando algoritmos de detección de bordes o de agrupación de píxeles.

En resumen, el pre procesamiento de una imagen de fondo de ojo implica la eliminación de artefactos de iluminación y del sistema de vasos sanguíneos, la corrección de la distorsión geométrica, el filtrado para mejorar la calidad de la imagen y la segmentación para identificar regiones de interés. Estos pasos son críticos para obtener una imagen de fondo de ojo clara y nítida que pueda ser utilizada para el diagnóstico del glaucoma.

3.1.4. Preprocesamiento De Texturas

Después del preprocesamiento de la imagen de fondo de ojo, el siguiente paso es la segmentación de la imagen para identificar regiones de texturas. En este proyecto, se utiliza un algoritmo de segmentación basado en adaptativos, cuadráticos, discriminantes locales (ALDL) para detectar las características de textura en la imagen. Este algoritmo se entrena con imágenes etiquetadas previamente como regiones de textura y regiones no texturizadas. Luego, el ALDL segmenta la imagen en regiones texturizadas y no texturizadas utilizando la información de la imagen y los criterios de entrenamiento. La segmentación se realiza en tiempo real, lo que permite una retroalimentación inmediata a los usuarios para realizar ajustes en la configuración del algoritmo. Una vez que se han identificado las regiones texturizadas, se pueden utilizar otros algoritmos para el análisis de patrones y la clasificación de las imágenes.

3.2. Investigación Universidad Autónoma del Estado de México

En la Universidad Autónoma del Estado de México (2020) se realizó un estudio sobre la Detección Automática de Glaucoma y Retinopatía Diabética Usando Características Cromáticas y Texturales, donde se establecieron las bases de los diferentes patrones como árboles de decisión, SVM y Naive Bayes. Se demostró el rendimiento de cada patrón utilizado haciendo hincapié en la clasificación del glaucoma y la retinopatía diabética. Entre los resultados se logró una comparación de desempeño de los clasificadores, así como la representación de la tasa de falsos positivos a los falsos negativos.

- El desempeño de clasificadores utilizando histogramas de gradientes:
 - En este se mostraron los resultados obtenidos con mejor desempeño obtenido con la utilización de redes neuronales y dándonos la peor clasificación que fue dada con el patrón de clasificación Bayesiana.
 - La métrica F-measure también conocida como F-score, la cual se utiliza para obtener la mayor precisión de una prueba y al igual que equilibra el uso de la precisión y el recall donde se deberán usar una prueba realista para esta métrica.
 - Área bajo la curva. Esta se define bajo dos parámetros: tasa de verdaderos positivos (TPR) y tasa de falsos positivos (FPR).
 - Una curva ROC representa TPR frente a FPR en diferentes umbrales de clasificación.
 - Reducir el umbral de clasificación clasifica más elementos como positivos, por lo que
 - aumentarán tanto los falsos positivos como los verdaderos positivos.
- Desempeño de clasificadores utilizando características de Haralick: Aquí se mostraron los resultados obtenidos utilizando solo características de Haralick.
 - Tanto la tasa de verdaderos positivos como la tasa de falsos positivos tienen un comportamiento similar en casi todos los clasificadores, sin embargo en este caso el clasificador con mejor desempeño son los árboles de decisión.

- Desempeño de clasificadores utilizando LBP: a pesar de mostrar resultados parecidos se sabe que este clasificador no es un método para la resolución de este problema.
 - Aquí el que obtuvo un mejor desempeño fue el método de regresión logística
 - Y el peor Fue el Bayesiano y el de árboles de decisión.

En la prueba mostrada en la investigación vemos lo siguiente; “Los resultados obtenidos con LBP y Haralick están siempre por debajo de HoG, pero con las características de Haralick son las que peores resultados arrojan de los tres tipos de características utilizados. Y por otro lado, es más claro ver que en los clasificadores entrenados con las características HoG tienen un mejor desempeño en comparación con las características de Haralick y LBP”.

3.3. Clasificador de redes neuronales para el diagnóstico de glaucoma

Entre las enfermedades oculares, el glaucoma es una de las principales causas de ceguera en todo el mundo. El común denominador del glaucoma es una neuropatía óptica característica, que se deriva de varios factores de riesgo, incluyendo la Presión Intraocular (PIO). Aunque la PIO elevada es claramente el factor de riesgo más frecuente de la atrofia del nervio óptico glaucomatoso, no es el único factor, y definir el glaucoma en función de la tensión ocular ya no se aconseja. La prevalencia mundial del glaucoma para la población de 40 a 80 años es del 3.54%. En 2013, se estimó que el número de personas con glaucoma en todo el mundo era de 64.3 millones. La característica diagnóstica más importante en el glaucoma es, por lo tanto, el aumento de la presión del líquido dentro del ojo que daña progresivamente las delicadas fibras del nervio óptico. Como el glaucoma crónico es inicialmente asintomático, la detección es de gran importancia para minimizar daños irreversibles en el ojo. Este trabajo forma parte del proyecto mundial para agilizar la detección de esta enfermedad en la actividad diaria oftálmica. Gran cantidad de datos están disponibles para los especialistas clínicos que tienen que evaluarlos y asignarlos a una patología específica. Para ayudar a los especialistas a hacerlo y evitar diagnósticos erróneos, se pueden utilizar métodos de inteligencia artificial. Sin embargo, todos ellos utilizan diferentes conjuntos de parámetros para el diagnóstico del glaucoma que el conjunto utilizado en este estudio. Los sistemas de diagnóstico asistido por computadora se basan en una amplia gama de clasificadores, como clasificadores bayesianos, máquinas de vectores de soporte, árboles de clasificación, funciones de base radial, redes neuronales, etc. Los clasificadores de redes neuronales artificiales (ANN) son ampliamente utilizados en el diagnóstico médico y han demostrado ser muy efectivos. Esta investigación tiene como objetivo desarrollar un sistema de predicción para el diagnóstico de glaucoma, basado en clasificadores de

Redes Neuronales (NN).

Material y Métodos

Los pacientes incluidos en el estudio actual fueron seleccionados de la práctica diaria en la Clínica Oftalmológica Review de Cluj Napoca, Rumania. Cada participante del estudio se sometió a una extensa evaluación oftalmológica, incluyendo pruebas de agudeza visual mejor corregida, biomicroscopía con lámpara de hendidura, medición de presión intraocular con ORA, gonioscopia, examen de fondo de ojo con una lente de 90 dioptrías, prueba de campo visual y mediciones OCT RNFL. El diagnóstico de glaucoma siguió el protocolo de Terminología de la Sociedad Europea de Glaucoma y Pautas para el Glaucoma. El estudio incluyó 240 ojos seleccionados: 122 de sujetos sanos (edad 19-92 años, edad promedio 51.24 años, desviación estándar 15.96) y 118 de pacientes con diagnóstico establecido de glaucoma (edad 19-89 años, edad promedio 63.75 años, desviación estándar 14.11). Se excluyeron ojos con otras patologías distintas al glaucoma. Esta investigación siguió los principios de la Declaración de Directrices de Helsinki y todos los participantes del estudio proporcionaron por escrito su consentimiento informado. Las redes neuronales se entrenaron para identificar automáticamente ojos sanos y glaucomatosos utilizando como datos de entrada la edad y las mediciones del analizador de respuesta ocular (ORA) y la Tomografía de Coherencia Óptica (OCT).

Capítulo 4

Metodología

En este Capítulo se describe detalladamente los pasos y métodos utilizados para la detección de glaucoma. En la Figura 4.1 se muestran los pasos utilizados para realizar la detección automática de glaucoma. Todos los procesos utilizados en nuestros experimentos son descritos en este Capítulo.

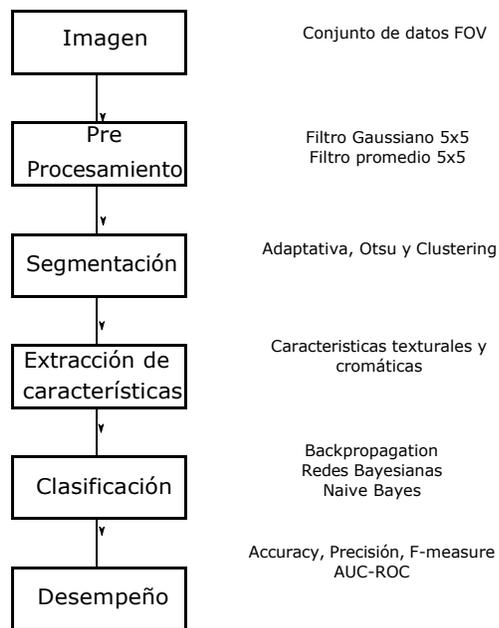


FIGURA 4.1: Pasos empleados para la detección de glaucoma

En la detección automática de glaucoma se utilizan los pasos comunes en un sistema de visión por computadora clásico. En este estudio, se comparan los resultados obtenidos utilizando redes neuronales con el desempeño obtenido mediante técnicas basadas en probabilidades. Ningún paso en el proceso se ha modificado, aunque las características utilizadas podrían mejorar el desempeño. Sin embargo, en este trabajo no se ha estudiado la influencia de las características en el desempeño de los clasificadores utilizados.

4.1. Pre procesamiento

En El filtrado Gaussiano y el filtrado promedio son técnicas comunes de pre-procesamiento utilizadas para reducir el ruido en las imágenes y mejorar la calidad de la imagen antes de realizar la segmentación. El filtrado Gaussiano utiliza una distribución Gaussiana para suavizar la imagen y eliminar el ruido, mientras que el filtrado promedio utiliza una media móvil para suavizar la imagen.

En el contexto de la detección de glaucoma, la aplicación de estos filtros ayuda a eliminar posibles características no deseadas en la imagen, como pequeñas irregularidades en la imagen o fluctuaciones en la iluminación, que pueden dificultar la detección precisa del borde de la cabeza del nervio óptico. Como resultado, la calidad de la segmentación mejora y se obtienen mejores resultados de detección.

En nuestra investigación utilizamos dos filtros: filtro Gaussiano 5×5 y filtro promedio 5×5 . Estos filtros permiten reducir imperfecciones en las imágenes lo que ayuda a mejorar la calidad de la segmentación.

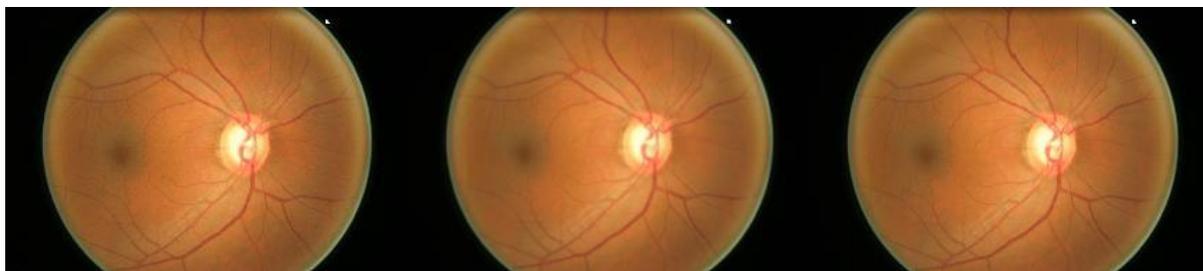


FIGURA 4.2: Imagen original (izquierda) e imágenes preprocesadas con filtro Gaussiano 5×5 (centro) y filtro promedio 5×5 (derecha)

4.2. Segmentación

La segmentación, se puede continuar con la extracción de características relevantes para la detección de glaucoma.

El método de clustering es una técnica de aprendizaje no supervisado que agrupa datos similares en grupos llamados clústeres. En el contexto de la segmentación de imágenes, se busca agrupar píxeles similares en la imagen en una región homogénea. En este caso, se utilizó el algoritmo K-means para la segmentación, donde se especifica el número de clústeres a generar (en este caso, dos: la región del fondo del ojo y la región circundante).

La segmentación es un paso crítico en la detección automática de glaucoma, ya que la región de interés puede ser pequeña en comparación con la imagen completa y puede haber variabilidad en la calidad de las imágenes. Una segmentación precisa puede mejorar la detección de características relevantes y, en última instancia, mejorar el desempeño del clasificador utilizado para la detección de glaucoma. La Figura 4.3 los resultados de la segmentación. La parte en negro es la región no deseada, mientras que la parte en blanco representa a la región de interés. Una vez obtenida la región de interés esta es definida por las coordenadas de los píxeles en blanco que son recuperadas para extraer toda la información de los píxeles a color.

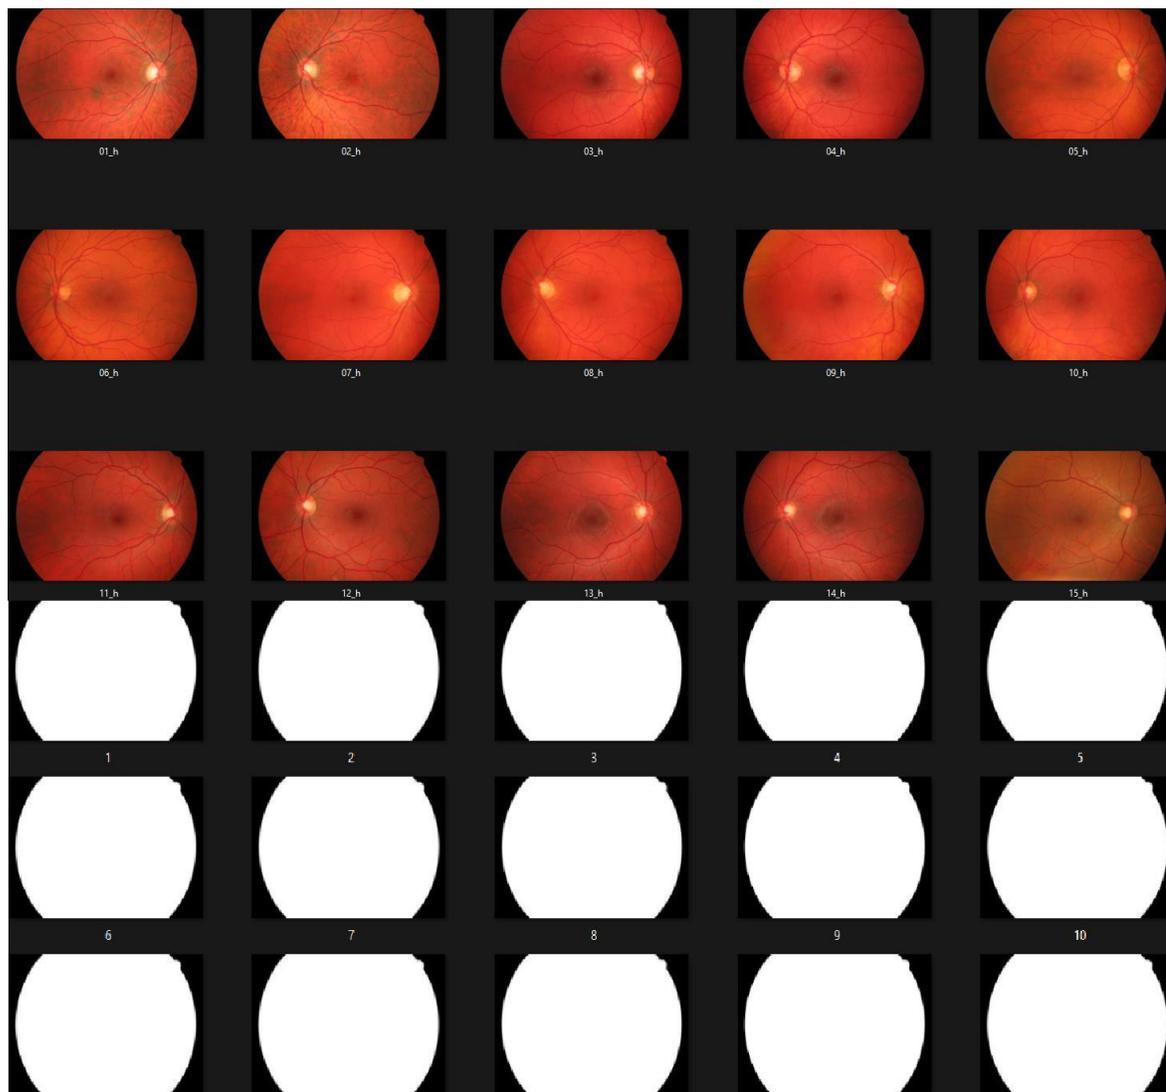


FIGURA 4.3: Obtención de región de interés utilizando segmentación de Otsu

4.3. Extracción de características

Una buena segmentación ayuda a obtener de forma precisa solo la región importante. Sin embargo, solo nos da información de los límites de esa región. Para obtener información de la región segmentada, es necesario utilizar extractores de características. Los extractores nos permiten describir y cuantificar mediante valores la región de interés. Cada extractor de características nos proporciona una característica especial de la región de interés.

Las características se pueden clasificar en tres grandes grupos: texturales, geométricas o cromáticas. En esta tesis, se extrajeron dos tipos de características.

1. Características texturales
2. Características cromáticas

Se extrajeron las siguientes características cromáticas :

1. Momentos de Hu con intensidad para cada canal en RGB y HSV.
2. Características HoG piramidales con intensidad.
3. Características de Gabor.
4. Media de intensidad para cada canal.
5. Desviación estándar para cada canal.
6. Contraste para cada canal.
7. Gradiente en el borde para cada canal.
8. Patrones binarios locales para cada canal.
9. Intensidad de curtosis para cada canal.

Mientras que se utilizaron solamente descriptores texturales de Haralick como características texturales. En total se extrajeron 1992 características texturales y cromáticas.

4.4. Clasificación e identificación

La clasificación es uno de los pasos más importantes en un sistema de visión.

La eficiencia del sistema dependen en gran parte del clasificador utilizado, esta es la principal razón por la que es necesario hacer un análisis comparativo con los distintos métodos de clasificación. En esta tesis, se hace un análisis comparativo con distintos clasificadores midiendo el desempeño con diversas métricas. Los métodos de clasificación utilizados en esta tesis son: Redes Bayesianas, Naive Bayes, redes neuronales y SVM.

En todos los experimentos se utilizó validación cruzada $k - fold$ con $k = 10$ para garantizar que los resultados son independientes de los datos de entrenamiento y prueba. La validación cruzada [Hagan, 1996] calcula la media aritmética obtenida de las diferentes evaluaciones sobre diferentes particiones. Esto permite validar el desempeño real de un modelo en la práctica.

4.5. Análisis de desempeño

Para hacer una análisis de los resultados es necesario utilizar métricas y comparar los resultados obtenidos de los diferentes métodos utilizados. En los experimentos llevados a cabo se utilizaron las métricas de desempeño Precisión, AUC-ROC, F-measure, accuracy y Recall. Todas estas métricas se describen a continuación:

1. Verdaderos positivos(VP). Número de casos que la prueba declara positivos y que son verdaderamente positivos [21].
2. Verdaderos negativos(VN). Número de casos que la prueba declara negativos y que son realmente negativos [21].
3. Falsos positivos(FP). Número de casos que la prueba declara positivos y que en realidad son negativos [21].
4. Falsos negativos(FN). Número de casos que la prueba declara negativos y que en realidad son positivos [21].
5. Precisión La precisión es aquello que nos ayudara a medir la calidad del modelo que se estará usando en este caso lo asociaremos con la parte de los algoritmos de clasificación, con esto podremos hacer una “Predicción” de los resultados. Como se muestra en la siguiente formula:

$$precision = \frac{TP}{TP + FP} \quad (4.1)$$

donde: TP representa la cantidad de Verdaderos positivos (True positive, TP por sus siglas en ingles) y FP representa la cantidad de Falsos Positivos (False positive, FP por sus siglas en ingles) [21].

6. AUC-ROC Es aquel donde se podrá visualizar de manera gráfica los problemas de la clasificación, la manera en la que podemos observar es la llamada área bajo la curva, la que nos indicará el rendimiento del algoritmo de clasificación multi-clase, es una de las técnicas más importantes ya que con esta lo que podremos comprobar es el rendimiento de cualquier modelo de clasificación [21].

7. F-measure Es un valor importante y sencillo de calcular, ya compara el rendimiento combinado de la precisión y la exhaustividad entre varias soluciones, pero la diferencia de esta es que debemos de calcular la precisión y la exhaustividad, pero una de sus ventajas es poder definir valores de manera aleatoria [21].

$$F1 = 2 \left(\frac{precision * recall}{precision + recall} \right) \quad (4.2)$$

8. Accuracy Sin lugar alguna la favorita o por lo menos la más usada, ya que con esta lo que tenemos es uno de los modelos más acertados, pero al igual una de las métricas más engañosas.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.3)$$

donde:

TP: True positive

TN: True negative

[21].

9. Recall Las métricas de integridad nos dirán cuántos modelos de aprendizaje automático son capaces de identificar [21]

$$recall = \frac{TP}{TP + FN} \quad (4.4)$$

donde:

TP: True positive

TN: False negative

.

Capítulo 5

Resultados experimentales

Este Capítulo describe los resultados y un análisis comparativo de los resultados experimentales llevados a cabo.

En los experimentos se extrajeron las características descritas en el Capítulo anterior, estas son utilizadas para entrenar los clasificadores. Los experimentos se llevan a cabo con los tres métodos de clasificación para comparar los desempeños. En todas las pruebas realizadas se utilizaron varias métricas de comparación.

5.1. Conjuntos de Imágenes

Utilizamos dos conjuntos de imágenes para realizar los experimentos en esta sección se describen los conjuntos de datos utilizados

5.1.1. Conjunto de Imágenes 1

El primer conjunto de imágenes fue obtenido de [6] este ha sido utilizado por los mismos autores en varios artículos [5]. El conjunto de datos puede ser encontrado en <https://www5.cs.fau.de/research/data/fundus-images/>.

El conjunto de imágenes esta compuesto por 45 imágenes de tres clases:

1. Conjunto de imágenes con problemas de retinopatía diabética
2. Conjunto de imágenes con padecimiento de glaucoma
3. Conjunto de imágenes saludables

La Figura 5.1 muestra el conjunto de datos utilizado. La fila a) muestra el conjunto de imágenes con problemas de retinopatía diabética. La fila b) muestra el conjunto de imágenes con padecimiento de glaucoma. Y la fila c) muestra el conjunto de imágenes saludables.

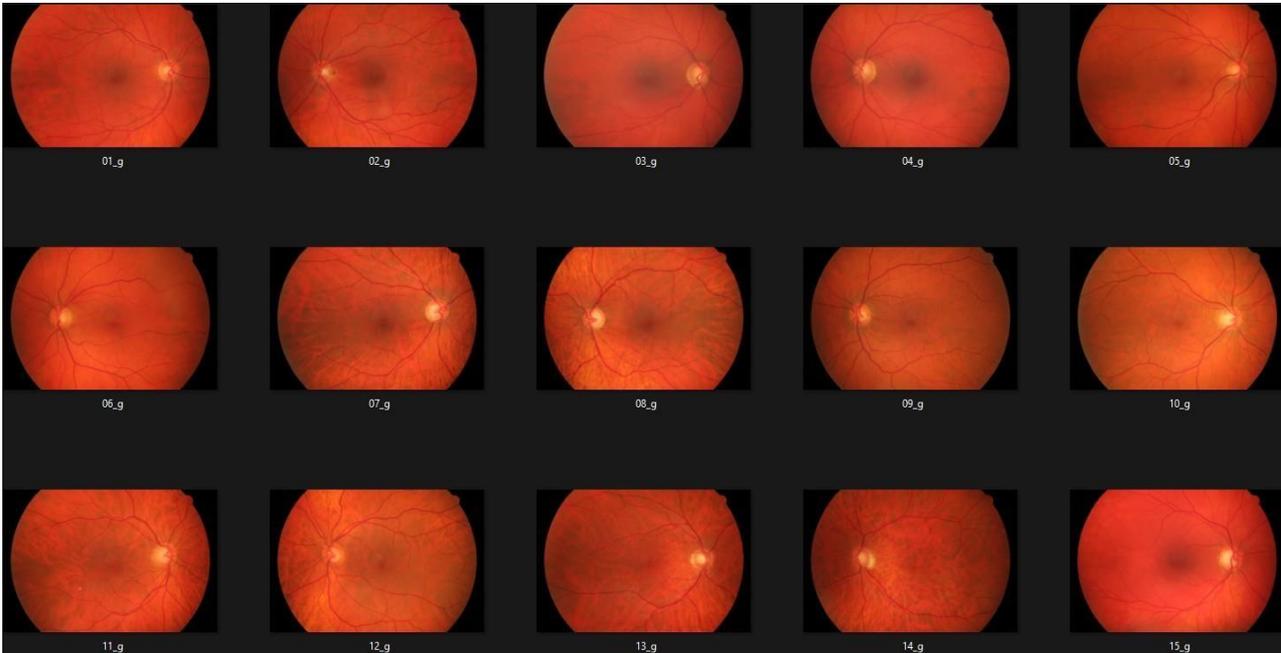


FIGURA 5.1: Conjunto de datos 1 utilizado con imágenes Glaucomatosas

5.1.2. Conjuntos de Imágenes Singapore Malay Eye Study (SiMES)

SiMES es un estudio que tiene como objetivo principal evaluar las causas y los factores de riesgo de la ceguera y la discapacidad visual en la comunidad malaya de Singapur [37]. Este estudio fue realizado durante un período de 3 años, de 2004 a 2007, por el Instituto de Investigación Ocular de Singapur y financiado por el Consejo Nacional de Investigación Médica. SiMES examinó a 3280 adultos malayos de 40 a 80 años, de los cuales 149 son pacientes con glaucoma. Se tomaron imágenes de fondo de retina para ambos ojos para cada sujeto en el estudio. Todas las imágenes de la retina han sido desidentificadas mediante la eliminación de cualquier información identificable individualmente antes de ser depositadas en ORIGA-light [37].

En conjunto de imágenes esta organizado de la siguiente manera: Los autores seleccionaron 520 imágenes (incluidas 134 imágenes glaucomatosas y 386 imágenes no glaucomatosas, todas ellas seleccionadas al azar) del estudio SiMES. Cada imagen está segmentada y anotada por profesionales capacitados del Instituto de Investigación del Ojo de Singapur utilizando ORIGA-GT. Los resultados de la segmentación y la anotación se almacenan en un servidor centralizado a través de una conexión de red. La interfaz web se implementa para permitir el acceso a la información en línea, la navegación, la búsqueda y la descarga, etc.

Todas las imágenes se dan en formato JPG con una resolución de 3072×2048

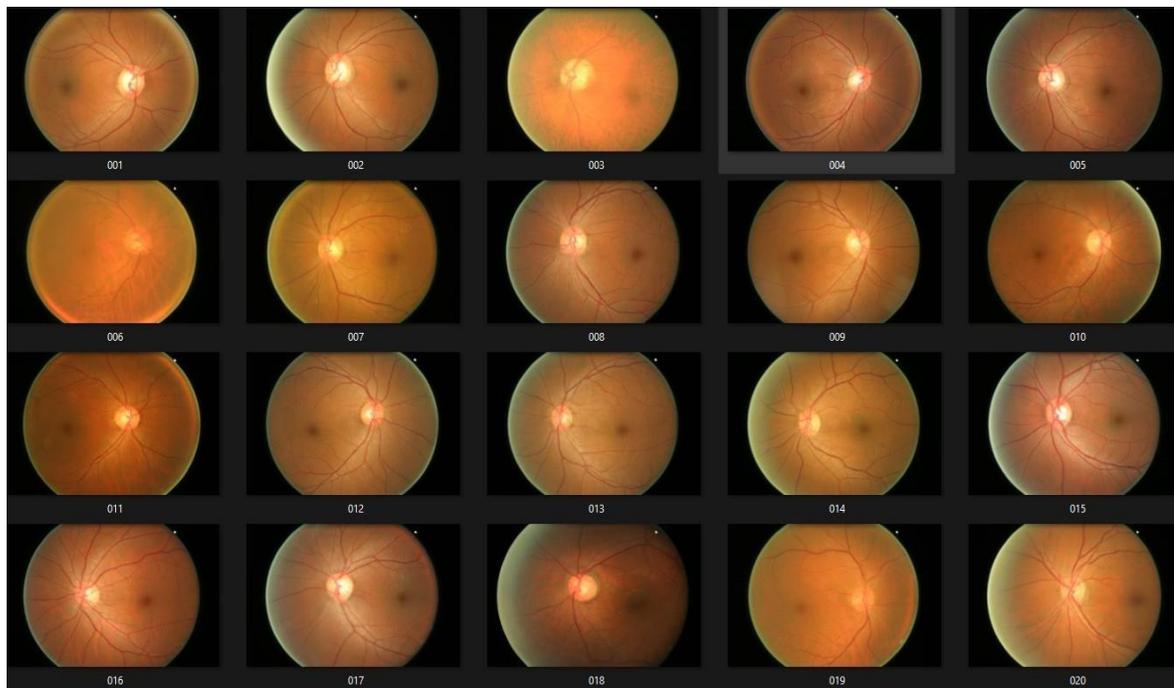


FIGURA 5.2: Conjunto de datos SiMES utilizado con imágenes no glaucomatosas

5.1.3. Normalización de datos

Normalización estadística

La normalización estadística es la transformación de escala de la distribución de una variable con el objetivo de poder hacer comparaciones respecto a conjuntos de elementos y a la media, eliminando los efectos de influencias [28]. En otras palabras, la normalización se refiere a la transformación de unidades de medida en diferentes escalas, lo que nos ayuda a hacer una comparación de elementos de manera adecuada.

Normalización	Fórmula	Tablas (Distribuciones)
Puntuación tipificada o estándar	$\frac{X - \mu}{\sigma}$	Normal estándar
T de Student	$\frac{X - \bar{X}}{s}$	T-Student
Coefficiente de variación	$\frac{\mu}{\sigma}$	Poisson
Momento estandarizado	$\frac{\mu_k}{\sigma_k}$	-

FIGURA 5.3: Técnicas de normalización de datos

La puntuación ayudará a la normalización de los errores cuando podamos calcular los parámetros muestrales. La normalización en la distribución t de Student es un tipo de normalización deductiva y se utiliza para determinar si hay una diferencia significativa entre las medidas de dos grupos. El coeficiente de variación utiliza la media como medida de escala, a diferencia de la puntuación tipificada y la t de Student, que utilizan la desviación estándar. La distribución se normaliza para las distribuciones de Poisson y exponencial. Esta utilizará valores entre 0 y 1. Si el coeficiente se aproxima a 0, significa que existe poca variabilidad en los datos y es una muestra muy compacta; en cambio, si tiende a 1, es una muestra muy dispersa y la medida perderá confiabilidad. El momento estandarizado puede aplicarse a cualquier distribución de probabilidad que tenga una función generadora de momentos, es decir, que las integrales de los momentos sean convergentes.

Aplicaciones

Aunque comúnmente se asocie a estudios demográficos, económicos y sociológicos, gran parte de los logros de la estadística se derivan del interés de los científicos por desarrollar modelos que expliquen el comportamiento de las propiedades de la materia y de los caracteres biológicos. La medicina, la biología, la física y, en definitiva, casi todos los campos de las ciencias emplean instrumentos estadísticos de importancia fundamental para el desarrollo de sus modelos de trabajo [28]. La estadística es una ciencia de aplicación práctica casi universal en todos los campos científicos:

- En las ciencias naturales: se emplea con profusión en la descripción de modelos termodinámicos complejos (mecánica estadística), en física cuántica, en mecánica de fluidos o en la teoría cinética de los gases, entre otros muchos campos.
- En las ciencias sociales y económicas: es un pilar básico del desarrollo de la demografía y la sociología aplicada.
- En economía: suministra los valores que ayudan a descubrir interrelaciones entre múltiples parámetros macro y microeconómicos.
- En las ciencias médicas: permite establecer pautas sobre la evolución de las enfermedades y los enfermos, los índices de mortalidad asociados a procesos morbosos, el grado de eficacia de un medicamento, etcétera.

Componente Normalizar datos

En este artículo se describe un componente del diseñador de Azure Machine Learning que se llama normalización. La normalización es una técnica que se aplica con frecuencia como parte de la preparación de datos para el aprendizaje automático. La normalización evita problemas en el modelado al crear nuevos valores que mantienen la distribución general y las relaciones en los datos de origen, mientras se conservan los valores dentro de una escala que se aplica a todas las columnas numéricas que se usan en el modelo. Puede aplicar la normalización a una sola columna o a varias columnas en el mismo conjunto de datos. Es importante destacar que otros algoritmos también pueden realizar su propio escalado o normalización de datos. [19]

Configurar Normalize Data

Con este componente, solo puede aplicar un método de normalización a la vez. Entonces, se aplicará el mismo método de normalización a todas las columnas que seleccione.

1. Agregue el componente Normalizar datos a la canalización. Puede encontrar el componente de Azure Machine Learning en Transformación de datos, en la categoría Escalar y reducir.
2. Conecte un conjunto de datos que contenga al menos una columna de todos los números.
3. Utilice el selector de columnas para seleccionar la columna numérica para normalizar. Si no selecciona una sola columna, todas las columnas de tipo numérico se incluyen en la entrada de forma predeterminada y se aplicará el mismo proceso de normalización a todas las columnas seleccionadas.
4. Use 0 para las columnas de constantes cuando esté activada: seleccione esta opción cuando cualquier columna numérica contenga un único valor invariable. Esto garantiza que estas columnas no se usen en las operaciones de normalización.
5. Transformation method (Método de transformación), elija una sola función matemática que se aplicará a todas las columnas seleccionadas.

- **Zscore:** Convierte todos los valores en puntuación z.

$$z = \frac{x - \text{mean}(x)}{\text{stdev}(x)} \quad (5.1)$$

La media y la desviación estándar se calculan por separado para cada columna. Se usa la desviación estándar poblacional.

- **MinMax:** el normalizador mínimo-máximo vuelve a escalar linealmente todas las características del intervalo [0,1].

$$z = \frac{x - \text{min}(x)}{[\text{max}(x) - \text{min}(x)]} \quad (5.2)$$

- **Logística:** Los valores de la columna se transforman mediante la fórmula siguiente:

$$z = \frac{1}{1 + \exp(x)} \quad (5.3)$$

- **LogNormal:** Esta opción convierte todos los valores en una escala logarítmica normal.

$$z = \text{Lognormal.CFD}(x; ; \mu, \sigma) \quad (5.4)$$

Aquí μ y σ son los parámetros de la distribución, calculados empíricamente a partir de los datos como las estimaciones de verosimilitud máxima para cada columna por separado.

- **TanH:** Todos los valores se convierten en una tangente hiperbólica.

$$p(k|x; \theta) = \frac{[E(Y|x)]^k e^{-E(Y|x)}}{k!} \quad (5.5)$$

1. Envíe la canalización o haga doble clic en el componente Normalizar datos y seleccione Ejecutar seleccionado[19].

5.2. Desempeño de clasificadores (Conjunto de datos 1)

En esta sección se analizan los resultados de precisión obtenidos en el primer conjunto de datos. La Tabla 5.1 muestra los resultados de precisión utilizando todas las características (1992 características).

Las columnas de la tabla muestran las precisiones obtenidas, donde tenemos las siguientes columnas en la tabla: La primera columna muestra los clasificadores utilizados. En los resultados experimentales se utilizó Naive Bayes, Redes Bayesianas y Redes Neuronales utilizando el algoritmo backpropagation. La segunda columna muestra los resultados obtenidos con la métrica de precisión, la tercera columna la métrica AUC-ROC que representa el área bajo la curva, la cuarta columna la métrica F-Measure y la quinta columna muestra la clase sobre la que se obtuvieron los resultados mostrados.

La Tabla 5.1 muestra los resultados obtenidos utilizando todas las características. Como se muestra en la tabla, el mejor desempeño es obtenido utilizando redes Bayesianas, particularmente en la clase 1. La clase 3 obtiene mejores resultados con Naive Bayes y redes neuronales. Por otro lado, el clasificador que peor desempeño tuvo

en promedio fue Naive Bayes, mientras que la peor clase clasificada fue la clase 2 utilizando nuevamente el algoritmo de Naive Bayes.

TABLA 5.1: Resultados utilizando todas las características

	TP Rate	FP Rate	Precisión	F-Measure	AUC-ROC	Clase
	0.867	0.033	0.929	0.897	0.942	1
Red Bayesiana	0.867	0.067	0.867	0.867	0.971	2
	0.867	0.100	0.813	0.839	0.944	3
Naive Bayes	0.867	0.067	0.867	0.867	0.934	1
	0.867	0.000	1.000	0.929	0.942	2
	0.933	0.100	0.824	0.875	0.934	3
Backpropagation	0.800	0.100	0.800	0.800	0.909	1
	0.867	0.033	0.929	0.897	0.987	2
	0.867	0.100	0.813	0.839	0.907	3

Es importante puntualizar que los resultados obtenidos con esta métrica son importantes cuando los conjuntos de datos son balanceados. Sin embargo, no nos dan ninguna medida de la sensibilidad y especificidad del clasificador. La Tabla 5.4 muestra los resultados obtenidos con F-measure, que es otra métrica de desempeño utilizada en aprendizaje máquina.

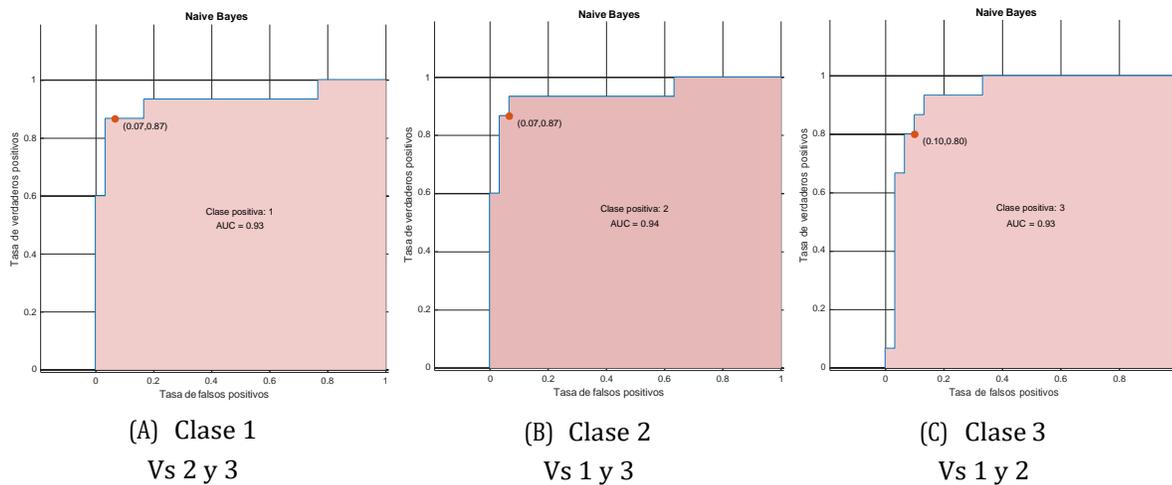


FIGURA 5.4: Gráficas AUC-ROC del clasificador Naive Bayes para las 3 diferentes clases

Generalmente, para evaluar un clasificador se utiliza la precisión. Esta se obtiene como el número de predicciones correctas de todas las predicciones realizadas. Sin embargo, la precisión por sí sola no nos da suficiente información para calificar qué tan bueno es un clasificador. Para ello, es necesario utilizar otras métricas de desempeño como F-measure. Esta métrica se utiliza para medir la precisión de una prueba y utiliza además de la precisión la

precisión la sensibilidad del modelo. F-measure suele proporcionar una medida más realista del rendimiento de un modelo. Por otro lado, el área bajo la curva muestra el rendimiento de un modelo de clasificación en todos sus umbrales.

En la Figura 5.4 se muestran tres gráficas AUC-ROC. La gráfica 5.4 a) muestra la gráfica AUC-ROC tomando la clase 1 como positiva y las clases 2 y 3 como negativas. La gráfica 5.4 b) muestra la gráfica AUC-ROC tomando la clase 2 como positiva y las clases 1 y 3 como negativas. Mientras que la gráfica 5.4 c) muestra la gráfica AUC-ROC tomando la clase 3 como positiva y las clases 1 y 2 como negativas.

5.3. Desempeño de clasificadores utilizando Conjunto de datos SiMES dataset

El segundo conjunto de datos es citado en [7] y [37] este puede ser obtenido en <https://www.kaggle.com/datasets/sshikamaru/glaucoma-detection>. El conjunto de datos contiene 650 imágenes con una resolución de 3072×2048 pixeles.

El conjunto de datos tiene 501 imágenes de personas sanas y 149 con glaucoma, es decir este conjunto de datos está un poco desbalanceado. Sin embargo, esto nos puede dar una idea del comportamiento del clasificador bajo condiciones que no son las más óptimas.

El conjunto de datos es claramente desbalanceado, con más datos en la clase negativa (sanos) que en la clase positiva (glaucoma).

TABLA 5.2: Resultados para la detección de glaucoma

Clasificador	Métrica de desempeño				
	TP	FP	Precisión	F-measure	ROC
Redes Bayesianas	0.765	0.593	0.740	0.720	0.695
Naive Bayes	0.740	0.417	0.741	0.741	0.732
Backpropagation	0.783	0.524	0.765	0.753	0.768

La Tabla 5.2 muestra los resultados obtenidos con el conjunto de datos 2 con solo dos clases, la clase con imágenes de personas sanas y la clase con imágenes de personas que sufren glaucoma. La Tabla muestra los resultados con todas las características extraídas. En la Tabla, es posible ver que los mejores resultados son obtenidos con Redes Bayesianas, con una mejor área bajo la curva, F-measure y precisión.

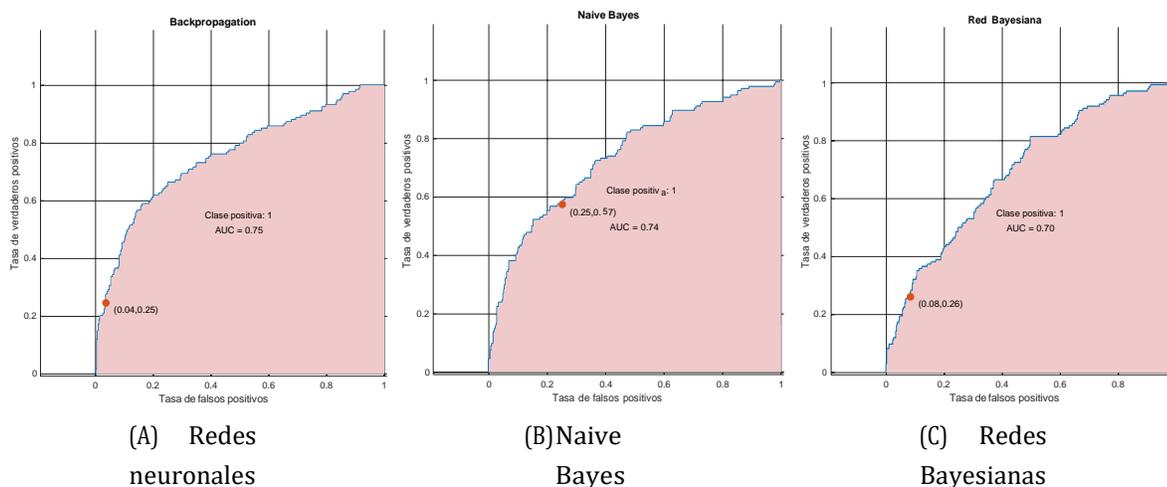


FIGURA 5.5: Gráficas AUC-ROC de los clasificadores Backpropagation, Naive Bayes y red Bayesiana

En la Figura 5.5 se muestran 3 gráficas AUC-ROC. La gráfica 5.5 a) muestra la gráfica AUC-ROC obtenida utilizando redes neuronales. La gráfica 5.5 b) muestra la gráfica AUC-ROC utilizando el algoritmo Naive Bayes. Mientras que la gráfica 5.5 c) muestra la gráfica AUC-ROC utilizando redes Bayesianas.

Capítulo 6

Conclusiones

En En esta tesis, se utilizaron técnicas probabilísticas y redes neuronales para identificar glaucoma a través de imágenes. En los resultados experimentales, se presentan los resultados obtenidos con ambas técnicas y se realiza un análisis comparativo de los mismos. Se utilizan varias métricas de desempeño para comparar los resultados.

De los resultados obtenidos, se puede deducir que el desempeño obtenido con ambos algoritmos es comparable. Sin embargo, los tiempos de entrenamiento obtenidos con técnicas probabilísticas son mucho mejores que los obtenidos con métodos basados en redes neuronales.

Como trabajo futuro, se debería realizar un análisis comparativo con técnicas basadas en aprendizaje profundo y evaluar los tiempos de entrenamiento. Además, sería muy importante implementarlo en dispositivos electrónicos para su uso. Esto requiere de un mayor trabajo y de otras pruebas sobre conjuntos de datos diferentes para probar el desempeño bajo esas condiciones. En esta tesis, solo se reportan los desempeños obtenidos bajo los conjuntos de imágenes descritos en esta tesis.

Bibliografía

- [1] Diego Almeida-Galarraga **and others**. «Glaucoma detection through digital processing from fundus images using MATLAB». **in** *2021 Second International Conference on Information Systems and Software Technologies (ICI2ST)*: IEEE, 2021, **pages** 39–45. ISBN: 978-1-6654-0411-2. DOI: [10 . 1109 / ICI2ST51859 . 2021 . 00014](https://doi.org/10.1109/ICI2ST51859.2021.00014). URL: <https://ieeexplore.ieee.org/document/9447345/>.
- [2] AhmadA Aref, ArdalanE Aminlari **and** IngridU Scott. «Glaucoma drainage implant surgery - An evidence-based update with relevance to Sub-Saharan Africa». **in** *Middle East African Journal of Ophthalmology*: 20 (2013), **page** 126. DOI: [10 . 4103/0974-9233.110607](https://doi.org/10.4103/0974-9233.110607). URL: <https://doi.org/10.4103%2F0974-9233.110607> (**urlseen** 01/09/2022).
- [3] Daniele M. S. Barros **and others**. «Machine learning applied to retinal image processing for glaucoma detection: review and perspective». **in** *BioMedical Engineering OnLine*: 19 (**april** 2020). DOI: [10 . 1186/s12938-020-00767-2](https://doi.org/10.1186/s12938-020-00767-2).
- [4] Akram Belghith **and others**. «Glaucoma progression detection using variational expectation maximization algorithm». **in** *2013 IEEE 10th International Symposium on Biomedical Imaging*: IEEE, 2013, **pages** 876–879. ISBN: 978-1-4673-6455-3. DOI: [10 . 1109/ISBI.2013.6556615](https://doi.org/10.1109/ISBI.2013.6556615). URL: <http://ieeexplore.ieee.org/document/6556615/>.
- [5] A. Budai **and others**. «Robust Vessel Segmentation in Fundus Images». **in** *International Journal of Biomedical Imaging*: 2013 (2013), **pages** 1–11. DOI: [10 . 1155 / 2013 / 154860](https://doi.org/10.1155/2013/154860).
- [6] Attila Budai **and others**. «Automatic Fovea Localization in Fundus Images». **in** *Informatik aktuell*: Springer Berlin Heidelberg, 2014, **pages** 114–119. DOI: [10 . 1007/978-3-642-54111-7_25](https://doi.org/10.1007/978-3-642-54111-7_25).
- [7] Jun Cheng **and others**. «Similarity regularized sparse group lasso for cup to disc ratio computation». **in** *Biomedical Optics Express*: 8.8 (2017), **page** 3763. DOI: [10 . 1364/boe . 8 . 003763](https://doi.org/10.1364/boe.8.003763).

- [8] Nikolay Chumerin **and others**. «P300 Detection Based on Feature Extraction in Online Brain-Computer Interface». in *KI 2009: Advances in Artificial Intelligence*: (2009), pages 339–346. DOI: [10.1007/978-3-642-04617-9_43](https://doi.org/10.1007/978-3-642-04617-9_43). (urlseen 28/08/2022).
- [9] Javier Civit-Masot **and others**. «Dual Machine-Learning System to Aid Glaucoma Diagnosis Using Disc and Cup Feature Extraction». in *IEEE Access*: 8 (2020), pages 127519–127529. DOI: [10.1109/access.2020.3008539](https://doi.org/10.1109/access.2020.3008539). (urlseen 17/05/2022).
- [10] J.M. Coughlan **and** A.L. Yuille. «Manhattan World: compass direction from a single image by Bayesian inference». in *Proceedings of the Seventh IEEE International Conference on Computer Vision*: IEEE, 1999. DOI: [10.1109/iccv.1999.790349](https://doi.org/10.1109/iccv.1999.790349).
- [11] Jamie Craig. *Laser Treatment / Glaucoma Australia*. glaucoma.org.au. URL: <https://glaucoma.org.au/what-is-glaucoma/glaucoma-treatments/laser-treatment/selective-laser-trabeculoplasty-slt>.
- [12] John Earman. *Reprinted from PROCEEDINGS OF THE BRITISH ACADEMY-III BAYES'S THEOREM 5 Bayes, Hume, Price, and Miracles*. URL: <https://sites.pitt.edu/~jearman/Earman2002a.pdf> (urlseen 23/07/2022).
- [13] E. Eells. «Review: Bayes's Theorem». in *Mind*: 113 (july 2004), pages 591–596. DOI: [10.1093/mind/113.451.591](https://doi.org/10.1093/mind/113.451.591). (urlseen 25/04/2020).
- [14] Karthikayani K. **and** A. R. Arunachalam. «A survey on deep learning feature extraction techniques». in *4TH INTERNATIONAL CONFERENCE ON THE SCIENCE AND ENGINEERING OF MATERIALS: ICoSEM2019*: (2020). DOI: [10.1063/5.0028564](https://doi.org/10.1063/5.0028564). (urlseen 28/08/2022).
- [15] Samina Khalid, Tehmina Khalil **and** Shamila Nasreen. «A survey of feature selection and feature extraction techniques in machine learning». in *2014 Science and Information Conference*: (august 2014). DOI: [10.1109/sai.2014.6918213](https://doi.org/10.1109/sai.2014.6918213).
- [16] Tehmina Khalil, Samina Khalid **and** Adeel M. Syed. *Review of Machine Learning techniques for glaucoma detection and prediction*. IEEE Xplore, august 2014. DOI: [10.1109/SAI.2014.6918224](https://doi.org/10.1109/SAI.2014.6918224). URL: <https://ieeexplore.ieee.org/document/6918224> (urlseen 07/05/2022).
- [17] Tae-Woo Kim **and others**. «Imaging of the Lamina Cribrosa in Glaucoma: Perspectives of Pathogenesis and Clinical Applications». in *Current Eye Research*: 38 (june 2013), pages 903–909. DOI: [10.3109/02713683.2013.800888](https://doi.org/10.3109/02713683.2013.800888). (urlseen 23/06/2021).

- [18] H. Leung and S. Haykin. «The complex backpropagation algorithm». in *IEEE Transactions on Signal Processing*: 39 (1991), pages 2101–2104. DOI: 10.1109/78.134446. (urlseen 15/04/2020).
- [19] likebupt. *Normalización de datos: referencia de componente - Azure Machine Learning*. docs.microsoft.com, july 2022. URL: <https://docs.microsoft.com/es-es/azure/machine-learning/component-reference/normalize-data> (urlseen 04/09/2022).
- [20] Ellery M. Lopez-Star and others. «Evaluación rápida de la ceguera evitable, incluida la retinopatía diabética, en Querétaro, México». in *Revista Mexicana de Oftalmología*: 92 (march 2019), 84–93. URL: <https://www.medigraphic.com/cgi-bin/new/resumen.cgi?IDARTICULO=85759> (urlseen 01/09/2022).
- [21] Jose Martinez Heras. *Precision, Recall, F1, Accuracy en clasificación - IArtificial.net*. IArtificial.net, october 2020. URL: <https://www.iartificial.net/precision-recall-f1-accuracy-en-clasificacion/>.
- [22] Shaoqing Meng and Chunping Hou. «Approach to congestion pattern analysis based on Bayesian Network». in *2010 International Conference on E-Health Networking Digital Ecosystems and Technologies (EDT)*: (april 2010). DOI: 10.1109/edt.2010.5496511. (urlseen 29/08/2022).
- [23] Silvia OVREIU and others. «Early Detection of Glaucoma Using Residual Networks». in *2020 13th International Conference on Communications (COMM)*: IEEE, 2020, pages 161–164. ISBN: 978-1-7281-5611-8. DOI: 10.1109/COMM48946.2020.9141990. URL: <https://ieeexplore.ieee.org/document/9141990/>.
- [24] Eduardo Pinos-Velez and others. «Implementation of support tools for the presumptive diagnosis of Glaucoma through identification and processing of medical images of the human eye». in *2018 IEEE International Systems Engineering Symposium (ISSE)*: IEEE, 2018, pages 1–5. ISBN: 978-1-5386-4446-1. DOI: 10.1109/SysEng.2018.8544409. URL: <https://ieeexplore.ieee.org/document/8544409/>.
- [25] Harry A. Quigley. «Open-Angle Glaucoma». in *New England Journal of Medicine*: 328.15 (1993), pages 1097–1106. ISSN: 0028-4793. DOI: 10.1056/NEJM199304153281507. URL: <http://www.nejm.org/doi/abs/10.1056/NEJM199304153281507>.
- [26] Md Mijanur Rahman and others. «Prospective Methodologies in Hybrid Renewable Energy Systems for Energy Prediction Using Artificial Neural Networks». in *Sustainability*: 13 (february 2021), page 2393. DOI: 10.3390/su13042393.

- [27] N. Elava rasan **and** Dr. K. Mani. «A Survey on Feature Extraction Techniques». **in***International Journal of Innovative Research in Computer and Communication Engineering*: 03 (january 2015), pages 52–55. DOI: [10 . 15680 / ijircce . 2015 . 0301009](https://doi.org/10.15680/ijircce.2015.0301009). ([urlseen 20/06/2019](#)).
- [28] Paula Rodó. *Aplicaciones de la estadística - hiru*. Hiru.eus, 2016. URL: <https://www.hiru.eus/es/matematicas/aplicaciones-de-la-estadistica>.
- [29] Volker Roeser. *Politik und religiose Toleranz vor dem ersten Hugenottenkrieg in Frankreich*. Helbing Lichtenhahn, 1985.
- [30] Ganesh Naga Sai Prasad V, Ratna Bhargavi V **and** Rajesh V. «Feature extraction based retinal image analysis for bright lesion classification in fundus image». **in***Biomedical Research*: 29 (2018). DOI: [10.4066/biomedicalresearch.29-16-2170](https://doi.org/10.4066/biomedicalresearch.29-16-2170). ([urlseen 01/09/2021](#)).
- [31] Hiram José Sandoval-Cuellar. «Image-based Glaucoma Classification Using Fundus Images and Deep Learning». **in** \emptyset : DOI: [10.17488/rmib.42.3.2](https://doi.org/10.17488/rmib.42.3.2).
- [32] A. Soltani **and**others. «A new expert system based on fuzzy logic and image processing algorithms for early glaucoma diagnosis». **in***Biomedical Signal Processing and Control*: 40 (february 2018), pages 366–377. DOI: [10.1016/j.bspc.2017.10.009](https://doi.org/10.1016/j.bspc.2017.10.009). ([urlseen 01/08/2020](#)).
- [33] Sushma Tejwani **and**others. «Treatment of glaucoma by prostaglandin agonists and beta-blockers in combination directly reduces pro-fibrotic gene expression in trabecular meshwork». **in***Journal of Cellular and Molecular Medicine*: 24 (april 2020), pages 5195–5204. DOI: [10.1111/jcmm.15172](https://doi.org/10.1111/jcmm.15172). ([urlseen 09/04/2021](#)).
- [34] Yan Tong **and**others. «Application of machine learning in ophthalmic imaging modalities». **in***Eye and Vision*: 7 (april 2020). DOI: [10 . 1186 / s40662 - 020 - 00183 - 6](https://doi.org/10.1186/s40662-020-00183-6).
- [35] Siamak Yousefi **and**others. «Learning From Data: Recognizing Glaucomatous Defect Patterns and Detecting Progression From Visual Field Measurements». **in***IEEE Transactions on Biomedical Engineering*: 61.7 (2014), pages 2112–2124. ISSN: 0018-9294. DOI: [10 . 1109 / TBME . 2014 . 2314714](https://doi.org/10.1109/TBME.2014.2314714). URL: <http://ieeexplore.ieee.org/document/6781613/>.
- [36] Lei Yu **and** Huan Liu. *Feature Selection for High-Dimensional Data: A Fast Correlation-Based Filter Solution*. 2003. URL: <https://www.aaai.org/Papers/ICML/2003/ICML03-111.pdf>.

-
- [37] Zhuo Zhang **and others**. «ORIGA^{light}: An online retinal fundus image database for glaucoma analysis and research». **in** *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology*: IEEE, 2010. DOI: [10.1109/iembs.2010.5626137](https://doi.org/10.1109/iembs.2010.5626137).