



UAEM | Universidad Autónoma
del Estado de México

UNIVERSIDAD AUTÓNOMA DEL ESTADO DE
MÉXICO

PROTOCOLO DE TESIS

**Análisis de Selección de Características para Mejorar el
Desempeño en la Detección de Retinopatía Diabética**

Tesis que presenta

Alexis Ariel GARCÍA DURAN

Para obtener el Grado de

Ingeniero en Computación

Asesor de Tesis:

Dr. Jair CERVANTES

Texcoco, Estado de México.

Octubre del 2024

Abstract

The detection of retinopathy using classical digital image processing techniques has been addressed in several studies in recent years. In pattern recognition, an important process for achieving acceptable accuracy is feature selection. Feature selection can reduce computational complexity and increase the reliability of classification. Moreover, it allows obtaining a subset of features with better discriminative power and can even eliminate features that may introduce noise into the classifier. Feature selection techniques range from the simplest to very elaborate techniques such as Genetic Algorithms. In this thesis, different feature selection techniques are implemented, and a comprehensive performance analysis is conducted for the detection of diabetic retinopathy.

Resumen

La detección de retinopatía utilizando técnicas clásicas de procesamiento digital de imágenes ha sido abordada en varias investigaciones en los últimos años. En reconocimiento de patrones un proceso importante para obtener una precisión aceptable es la selección de características. La selección de características puede reducir la complejidad computacional y aumenta la fiabilidad de la clasificación. Además de lo anterior, permite obtener un subconjunto de características con mejor poder discriminativo, e incluso eliminar características que pueden introducir ruido en el clasificador. Las técnicas de selección de características van desde las más sencillas hasta técnicas muy elaboradas como Algoritmos genéticos. En esta Tesis, se implementan diferentes técnicas de selección de características y se realiza un análisis exhaustivo del desempeño para la detección de retinopatía diabética.

Índice general

1. Introducción	2
1.1. Problemática	3
1.2. Justificación	4
1.3. Objetivos	5
1.4. Hipótesis	6
1.5. Antecedentes	6
1.5.1. Retinopatía	6
1.5.2. Glaucoma	7
1.5.3. Sistema de detección de retinopatía diabética y glaucoma	8
2. Preliminares	12
2.1. Técnicas de Clasificación	12
2.1.1. Neural networks	14
2.1.2. Support Vector Machines	17
2.1.3. Clasificación Bayesiana	20
2.1.4. Árboles de decisión	22
2.2. Técnicas de Evaluación de desempeño	24
2.2.1. Matriz de Confusión	24
2.2.2. Precisión	26
2.2.3. Recall (Sensibilidad)	26
2.2.4. F1-Score	26
2.2.5. Curva ROC y AUC (Área Bajo la Curva)	27

2.2.6. Exactitud (Accuracy)	28
2.3. Validación Cruzada	29
2.3.1. Tipos más comunes de Validación Cruzada	29
2.4. Técnicas de segmentación	30
2.5. Técnicas de Extracción de características	31
2.5.1. Características texturales de Haralick	31
2.5.2. Patrones binarios locales	34
2.6. Histograma de Gradientes Ordenados	35
2.6.1. Características cromáticas	36
3. Técnicas de selección de características	38
3.1. Selección hacia adelante	38
3.2. Eliminación hacia atrás	42
3.3. Algoritmos genéticos para selección de características	44
4. Metodología	47
4.1. Conjunto de datos utilizado	48
4.2. Pre procesamiento	50
4.3. Segmentación	50
4.4. Extracción de características	51
4.4.1. Normalización de datos	52
4.5. Clasificación e identificación	53
4.6. Validación y evaluación	54
5. Resultados experimentales	57
5.1. Conjunto A	57
5.1.1. Desempeño utilizando todas las características (Conjunto A)	59
5.1.2. Desempeño con selección de datos (Conjunto A)	60
5.2. Conjunto B	62
5.2.1. Desempeño utilizando todas las características (Conjunto B)	64
5.2.2. Desempeño con selección de datos (Conjunto B)	65

6. Conclusiones**67**

Índice de figuras

1.1. Pasos de un sistema de visión para detección automática de retinopatía y glaucoma diabético	9
2.1. Red neuronal convolucional	16
2.2. Optimización de frontera de decisión con una SVM	19
2.3. Clasificador Bayes	21
2.4. Árbol de decisión	24
2.5. Diferentes métricas de desempeño	27
2.6. Interpretación de AUC-ROC	28
2.7. Validación cruzada con $k = 5$	30
2.8. Extracción de características usando la matriz de coocurrencia	33
2.9. Algoritmo LBP	35
3.1. Selección de características Hacia Adelante	40
3.2. Eliminación de características Hacia Atras	43
4.1. Pasos utilizados para realizar el análisis en esta tesis	48
4.2. Conjunto de datos utilizado a) Retinopatía diabética b) Glaucoma c) Saludable	49
5.1. Conjunto de datos utilizado a) Retinopatía diabética b) Glaucoma c) Saludable	58

5.2. Conjunto de datos utilizado a) Grado de retinopatía 0 b) Grado de retinopatía 1 c) Grado de retinopatía 2 d) Grado de retinopatía 3 e) Grado de retinopatía 4	64
--	----

Índice de cuadros

- 1.1. Clasificación de los tipos de retinopatía diabética, síntomas y métodos de diagnóstico 7
- 1.2. Clasificación de los tipos de glaucoma, síntomas y métodos de diagnóstico 7

- 5.1. Resultados utilizando todas las características 59
- 5.2. Resultados utilizando características reducidas por tres algoritmos 60
- 5.3. Resultados de la detección en grados de retinopatía 65

Capítulo 1

Introducción

La detección de retinopatía mediante técnicas clásicas de procesamiento digital de imágenes ha sido un tema abordado en diversas investigaciones en los últimos años. En este contexto, el reconocimiento de patrones emerge como un proceso fundamental para lograr una precisión aceptable en la identificación de esta enfermedad ocular. Una etapa crucial en el reconocimiento de patrones es la selección de características, la cual desempeña un papel vital en la optimización del rendimiento del sistema de detección.

La selección de características ofrece una serie de ventajas significativas en el proceso de análisis de imágenes médicas. Por un lado, puede contribuir a reducir la complejidad computacional del sistema, lo que resulta en tiempos de procesamiento más eficientes y un uso racional de recursos computacionales. Por otro lado, al seleccionar cuidadosamente las características más relevantes, se puede mejorar la precisión y confiabilidad de la clasificación de imágenes, al tiempo que se reduce el riesgo de sobreajuste [26].

Además de estas ventajas inherentes, la selección de características permite identificar un subconjunto óptimo de características con un poder discriminativo superior. Esto significa que el sistema de detección puede enfocarse en las características más informativas y relevantes para la tarea específica, ignorando aquellas que puedan introducir ruido o redundancia en el proceso de clasificación.

Las técnicas de selección de características abarcan desde enfoques simples y heurísticos hasta métodos más avanzados y sofisticados, como los Algoritmos Genéticos [10].

En el contexto de esta tesis, se implementan y evalúan diversas técnicas de selección de características, abarcando desde métodos clásicos como Análisis de Componentes Principales (PCA) y Selección de Características Basada en Filtros (FS), hasta enfoques más innovadores como la Selección de Características Basada en la Evolución (EFS).

A través de un análisis exhaustivo del rendimiento de estas técnicas en el contexto específico de la detección de retinopatía diabética, se busca en esta tesis identificar las estrategias más efectivas y eficientes para mejorar la precisión y confiabilidad del sistema de diagnóstico automatizado. Este estudio no solo contribuirá al avance del campo de la salud digital, sino que también puede tener un impacto significativo en la detección temprana y el tratamiento oportuno de enfermedades oculares críticas como la retinopatía diabética.

1.1. Problemática

El adecuado manejo de características para lograr una clasificación efectiva ha sido ampliamente discutido por numerosos investigadores, quienes se refieren a este proceso como el "curso de la dimensionalidad". Este fenómeno se manifiesta cuando el incremento en el número de características asociadas a un conjunto de datos, en lugar de facilitar el proceso de clasificación, afecta negativamente el rendimiento del clasificador. En muchas ocasiones, una alta dimensionalidad de características puede introducir ruido y confundir a los algoritmos de aprendizaje.

Por consiguiente, uno de los desafíos más importantes en la actualidad radica en la reducción de la dimensionalidad de características, ya que esto resulta fundamental para mejorar el desempeño en la etapa de clasificación. Este principio también se aplica en el contexto de la detección automática de retinopatía diabética, donde el uso de un gran número de características puede impactar negativamente en la precisión de la detección al introducir ruido en los clasificadores.

Un aspecto crucial al reducir el número de características es identificar aquellas que poseen un bajo poder discriminante, que introducen ruido en el proceso de clasificación, o que son poco confiables. Sin embargo, esta tarea no es sencilla debido a la complejidad

y la alta dimensionalidad de los datos involucrados.

En el marco de esta tesis, se emplean varios métodos de selección de características de vanguardia con el objetivo de mejorar la precisión en la clasificación de la retinopatía diabética. Estas técnicas están diseñadas para identificar de manera eficiente y efectiva las características más relevantes y discriminativas, contribuyendo así a mejorar la calidad y la confiabilidad del sistema de detección automática. Este enfoque no solo busca optimizar el rendimiento del sistema, sino también facilitar la interpretación de los resultados y el desarrollo de herramientas más efectivas para el diagnóstico precoz y el tratamiento de esta enfermedad ocular crítica.

1.2. Justificación

La selección de características desempeña un papel crucial en la optimización de los sistemas de clasificación, ya que no solo permite reducir el tamaño del conjunto de datos de entrenamiento, sino que también puede mejorar significativamente la precisión de la clasificación. Un análisis exhaustivo en este sentido no solo resulta fundamental, sino que además promete incrementar el desempeño en la detección de retinopatía diabética, un área de investigación de vital importancia en el ámbito médico.

Sin embargo, la selección de características en conjuntos de datos no es una tarea trivial. Los enfoques diseñados para este propósito deben ser capaces de identificar y retener no solo las características individuales más relevantes, sino también capturar toda la información relativa al poder discriminativo de las características combinadas. Esto implica un proceso meticuloso de evaluación y comparación de diferentes técnicas de selección de características, con el fin de determinar cuál es la más adecuada para el contexto específico de detección de retinopatía diabética.

Los resultados obtenidos de este análisis serán presentados y discutidos en detalle, proporcionando una visión clara de los beneficios y limitaciones de cada enfoque evaluado. Este enfoque metodológico riguroso tiene como objetivo último mejorar el desempeño en la detección de retinopatía diabética, ofreciendo así una contribución significativa al campo de la salud digital y al desarrollo de herramientas más efectivas para el diagnóstico

temprano y el tratamiento oportuno de esta enfermedad ocular crítica.

1.3. Objetivos

En el transcurso de esta tesis, llevaremos a cabo un análisis exhaustivo del comportamiento de diversas técnicas de selección de características aplicadas al conjunto de datos de retinopatía diabética. Con este propósito en mente, nos enfocaremos en los siguientes objetivos específicos:

1. Implementación de Algoritmos de Selección de Características: Nos dedicaremos a implementar y evaluar los algoritmos de selección de características más utilizados y relevantes en la literatura actual. Estos algoritmos se seleccionarán cuidadosamente para abarcar una amplia gama de enfoques y estrategias, con el fin de determinar cuál es el más efectivo para el contexto particular de detección de retinopatía diabética.
2. Implementación de Algoritmos de Clasificación: Además, pondremos en práctica al menos dos algoritmos de clasificación distintos con el objetivo de evaluar y probar el rendimiento del conjunto de datos de retinopatía diabética. Estos algoritmos serán seleccionados de acuerdo con su relevancia y popularidad en el ámbito de la clasificación de datos médicos, y servirán como herramientas fundamentales para la evaluación del desempeño de las técnicas de selección de características implementadas.
3. Análisis y Discusión de Resultados: Por último, realizaremos un análisis detallado y una discusión exhaustiva de los resultados obtenidos a través de nuestras implementaciones y experimentos. Este análisis incluirá la evaluación de la precisión de clasificación, la comparación de diferentes enfoques de selección de características, y la identificación de posibles desafíos o limitaciones encontradas durante el proceso. A partir de estos resultados, podremos extraer conclusiones significativas y proporcionar recomendaciones prácticas para futuras investigaciones en el campo de la detección de retinopatía diabética.

1.4. Hipótesis

Se espera que la implementación de diferentes técnicas de selección de características en el proceso de detección de retinopatía diabética resulte en una mejora significativa en la precisión y confiabilidad de la clasificación de imágenes médicas. Se hipotetiza que, al reducir la dimensionalidad del conjunto de datos mediante la selección cuidadosa de características relevantes, se logrará una mayor eficiencia computacional y se minimizará la introducción de ruido en los clasificadores.

Se espera que las técnicas más avanzadas de selección de características, como los algoritmos genéticos, proporcionen resultados aún más prometedores al identificar de manera óptima las características más discriminativas para la detección de retinopatía diabética.

Se anticipa que este enfoque metodológico resultará en una mejora significativa en el rendimiento del sistema de detección automática de retinopatía diabética en comparación con métodos convencionales.

1.5. Antecedentes

En esta Sección se describen los sistemas de visión artificial enfocados a la detección de retinopatía diabética y glaucoma.

1.5.1. Retinopatía

La retinopatía diabética es una complicación de la diabetes que afecta los vasos sanguíneos del tejido sensible a la luz en la parte posterior del ojo (retina). Puede llevar a la pérdida de visión si no se detecta y trata a tiempo [4].

Existen varios tipos en los que se basa un experto para clasificar la Retinopatía, la Tabla 5.1 muestra un breve resumen de la retinopatía diabética, síntomas y métodos utilizados para su diagnóstico.

Cuadro 1.1: Clasificación de los tipos de retinopatía diabética, síntomas y métodos de diagnóstico

Tipo	Clase	Síntomas	Diagnóstico
Retinopatía Diabética No Proliferativa (RDNP)	Leve	Visión borrosa o fluctuante	Evaluación de síntomas y antecedentes de diabetes.
	Moderada	Manchas o áreas de visión oscura	Pruebas de agudeza visual, Visualización directa de la retina para detectar signos de retinopatía.
	Severa	Visión de colores desvanecidos Pérdida de visión central o periférica	Imágenes detalladas de la retina para documentar cambios
Retinopatía Diabética Proliferativa (RDP)	Temprana	Hemorragias intrarretinianas, Aumento de presión intraocular, Desarrollo de nuevos vasos sanguíneos	Evaluación de la circulación sanguínea en la retina.
	Avanzada	en la retina, Hemorragias vítreas, proliferación fibrovascular	Detección de edema macular
	Alto riesgo		

1.5.2. Glaucoma

Por otro lado, el glaucoma es un grupo de enfermedades oculares que dañan el nervio óptico, a menudo asociado con un aumento de la presión intraocular. En caso de que el paciente no reciba un tratamiento oportuno, puede llevar a la pérdida de visión permanente. La Tabla 5.2 muestra un breve resumen del glaucoma, síntomas y métodos utilizados para su diagnóstico.

Cuadro 1.2: Clasificación de los tipos de glaucoma, síntomas y métodos de diagnóstico

Tipo	Síntomas	Diagnóstico
Ángulo Abierto	Pérdida gradual de la visión periférica (GAA)	Evaluación de síntomas y antecedentes familiares de glaucoma.
Ángulo Cerrado	Dolor intenso en el ojo	Pruebas de agudeza visual
Tensión Normal	Náuseas y vómitos	Evaluación de la presión dentro del ojo.
Congénito	Visión borrosa	Inspección directa del nervio óptico para detectar daño.
	Halos alrededor de las luces (GAC)	Evaluación del campo visual para detectar pérdida de visión periférica. Examen del ángulo de drenaje del ojo para clasificar el tipo de glaucoma. Medición del grosor corneal para ajustar las lecturas de presión intraocular. Imágenes detalladas del nervio óptico y la retina para evaluar el daño.

La retinopatía diabética está relacionada directamente con la diabetes y el control de la glucosa en sangre. Mientras que el glaucoma tiene causas multifactoriales, con factores de riesgo como la presión intraocular elevada, antecedentes familiares, edad avanzada y ciertos problemas médicos.

A menudo, la retinopatía diabética es asintomática en etapas tempranas, con síntomas visuales que se presentan en etapas avanzadas. Por otro lado, el glaucoma es generalmente asintomático en etapas tempranas (glaucoma de ángulo abierto), mientras que presenta síntomas agudos en casos de glaucoma de ángulo cerrado.

1.5.3. Sistema de detección de retinopatía diabética y glaucoma

Los sistemas de visión artificial enfocados a la detección de retinopatía diabética han sido diseñados para identificar y analizar los signos de esta enfermedad en imágenes del fondo del ojo. Estos sistemas combinan técnicas de procesamiento digital de imágenes, aprendizaje automático y algoritmos de inteligencia artificial para detectar automáticamente las características y anomalías asociadas con la retinopatía diabética. Un sistema automático de visión (ver Figura 1.1) funciona con los pasos que se describen a continuación:

1. **Adquisición de Imágenes:** En este paso inicial se utilizan cámaras especializadas, como las cámaras de fondo de ojo o retinógrafos, para capturar imágenes de alta resolución de la retina del paciente. Estas imágenes suelen ser en color y pueden incluir diferentes tipos de capturas, como imágenes de campo amplio o imágenes con angiografía fluoresceínica.
2. **Preprocesamiento de Imágenes:** Antes de analizar las imágenes, se aplican técnicas de preprocesamiento para mejorar la calidad de las imágenes y eliminar ruido. Esto puede incluir ajuste de contraste, filtrado, normalización de iluminación y eliminación de artefactos mediante diversos filtros.
3. **Segmentación de Imágenes:** El siguiente paso es segmentar las diferentes estructuras de la retina, como los vasos sanguíneos, el nervio óptico y las áreas de interés. Algoritmos de segmentación, como la segmentación basada en regiones o la segmentación por contornos activos, Segmentación de Otsu se utilizan para identificar y aislar estas estructuras.

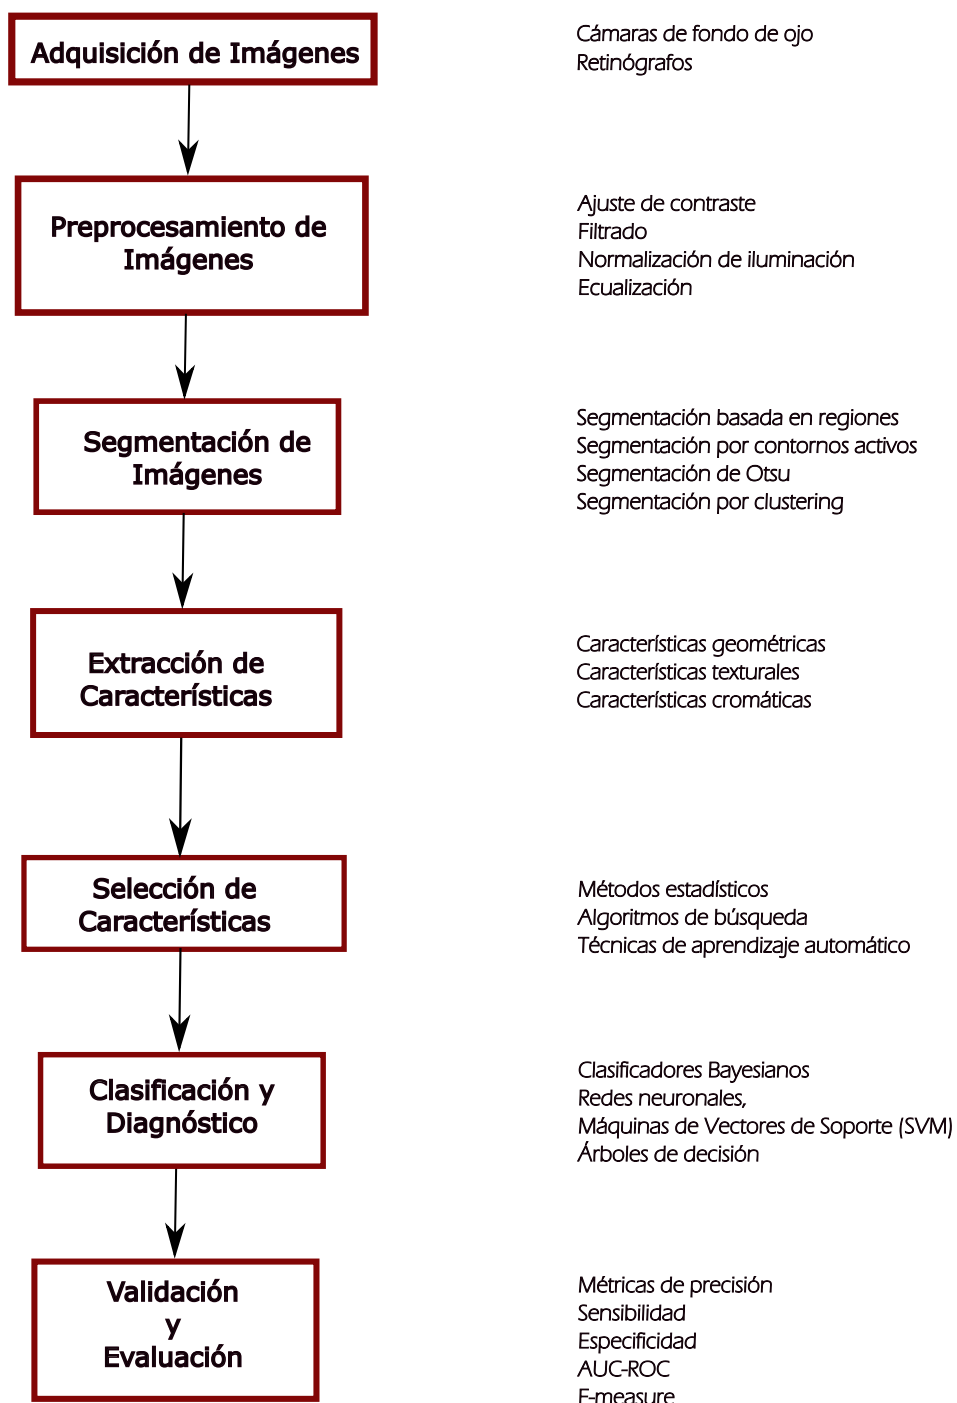


Figura 1.1: Pasos de un sistema de visión para detección automática de retinopatía y glaucoma diabético

4. **Extracción de Características:** Una vez segmentadas las imágenes, se extraen características relevantes que pueden incluir el tamaño, la forma, la textura y el color de las estructuras retinianas. Estas características se utilizan para identificar patrones y anomalías que son indicativos de retinopatía diabética, como microaneurismas, hemorragias, exudados y neovascularización.
5. **Selección de Características:** Para mejorar la eficiencia y precisión del sistema, se aplican técnicas de selección de características para elegir el subconjunto más relevante de características extraídas. Esto puede incluir métodos estadísticos, algoritmos de búsqueda o técnicas de aprendizaje automático, como los algoritmos genéticos.
6. **Clasificación y Diagnóstico:** Con el conjunto de características seleccionadas, se entrena un modelo de clasificación utilizando algoritmos de aprendizaje automático, como Clasificadores Bayesianos, redes neuronales, máquinas de soporte vectorial (SVM) o árboles de decisión. El modelo clasifica las imágenes en categorías, como «normal» o «retinopatía diabética» o «glaucoma», y puede proporcionar una evaluación de la severidad de la enfermedad.
7. **Validación y Evaluación:** El rendimiento del sistema se valida y evalúa utilizando conjuntos de datos de prueba que no fueron utilizados durante el entrenamiento. Se utilizan métricas como la precisión, sensibilidad, especificidad y el área bajo la curva ROC (AUC-ROC) para medir la efectividad del sistema.

El uso de métodos de inteligencia artificial permite obtener diferentes beneficios directamente como los siguientes:

1. **Detección Temprana:** Los sistemas de visión artificial pueden ser diseñados y entrenados para detectar signos tempranos de retinopatía diabética que podrían pasar desapercibidos en un examen manual.
2. **Consistencia y Fiabilidad:** Estos sistemas pueden proporcionar diagnósticos consistentes y reducir la variabilidad entre diferentes examinadores humanos.

3. Ahorro de Tiempo: Automatizan el proceso de análisis de imágenes, lo que permite a los profesionales de la salud manejar un mayor volumen de pacientes.
4. Accesibilidad: Pueden facilitar el acceso a diagnósticos en áreas remotas o con recursos limitados, donde los especialistas no están disponibles.

En resumen, los sistemas de visión artificial enfocados en la detección de retinopatía diabética representan una combinación poderosa de tecnología y medicina, mejorando la capacidad de los profesionales de la salud para diagnosticar y tratar esta enfermedad de manera oportuna y precisa.

Capítulo 2

Preliminares

En esta sección, se describen en detalle las técnicas de clasificación utilizadas en el estudio, que incluyen Máquinas de Vectores de Soporte (SVM), Redes Neuronales (NN), el clasificador de Bayes y los Árboles de Decisión. Cada una de estas técnicas se analiza con profundidad para comprender sus fundamentos teóricos, ventajas, desventajas y aplicaciones prácticas.

Por último, se abordan los métodos para evaluar el desempeño de los clasificadores y los modelos seleccionados. Se presentan métricas de evaluación como la exactitud, la precisión, la sensibilidad, la especificidad y el valor F1. También se explican técnicas de validación cruzada, que se utilizan para estimar la eficacia del modelo en datos no vistos y prevenir el sobreajuste.

2.1. Técnicas de Clasificación

La clasificación es una tarea fundamental en el ámbito del aprendizaje automático y la inteligencia artificial, con aplicaciones en diversos campos como el reconocimiento de imágenes, el análisis de texto, la detección de fraudes y la medicina. En esencia, consiste en organizar un conjunto de datos en grupos o categorías predefinidas, basándose en características o patrones distintivos que los diferencian entre sí.

Las clases, también conocidas como categorías o etiquetas, representan los grupos en los que se dividen los datos. Cada clase se define por un conjunto de características

o patrones específicos que la distinguen de las demás. Estas características pueden ser numéricas, categóricas o incluso una combinación de ambas. La definición precisa de las clases depende del problema específico que se esté abordando y del contexto en el que se aplica la clasificación.

Un clasificador es un modelo de aprendizaje automático entrenado para realizar la tarea de clasificación. Se le proporciona un conjunto de datos de entrenamiento que incluye ejemplos de cada clase, junto con sus respectivas etiquetas. A partir de este conjunto de datos, el clasificador aprende a identificar los patrones o características que discriminan entre las diferentes clases.

Para realizar una clasificación precisa, es fundamental definir y seleccionar el método óptimo. La elección del método adecuado se basa en varios factores, incluidos el tipo de datos disponibles, la naturaleza de las clases a identificar y los requisitos específicos del problema en cuestión. A continuación, se profundiza en estos aspectos:

Patrones y Similitudes: La identificación de patrones y similitudes es el primer paso crucial en la clasificación. Esto implica analizar las características cuantitativas de los individuos y determinar cómo se agrupan de manera natural. Los patrones pueden surgir de la observación de datos históricos, estudios experimentales o análisis de dominio específico. La identificación precisa de estos patrones es esencial para establecer clases que sean significativas y útiles para la tarea de clasificación.

Representación de Características: Los individuos se representan mediante vectores de características, donde cada vector contiene varios valores cuantitativos que describen aspectos específicos del individuo. La elección de las características adecuadas y su representación precisa afectan directamente la eficacia de la clasificación. En algunos casos, puede ser necesario transformar o normalizar las características para mejorar la comparabilidad entre diferentes individuos.

Proximidad y Distancia: La proximidad entre vectores de características y los centros de las clases se evalúa utilizando medidas de distancia, como la distancia euclidiana, la distancia de Manhattan o métricas más complejas como la distancia de Mahalanobis. La medida de distancia seleccionada puede influir significativamente en los resultados de la clasificación, especialmente en conjuntos de datos con alta dimensionalidad o caracterís-

ticas heterogéneas.

2.1.1. Neural networks

Las redes neuronales artificiales (RNAs) son un paradigma de aprendizaje automático inspirado en el funcionamiento del cerebro humano. Estas redes están diseñadas para reconocer patrones y aprender a partir de datos, haciéndolas muy útiles en muchas aplicaciones de la vida real que requieren procesamiento complejo y toma de decisiones basada en grandes volúmenes de información.

Estructura de las Redes Neuronales

La unidad básica de una RNA es la neurona artificial, una neurona artificial recibe una serie de entradas, las procesa a través de una función de activación y produce una salida [8]. Sin embargo una red neuronal puede estar conformada generalmente por al menos una capa de entrada, una capa oculta y una capa de salida. Todas estas conectadas completamente. La capa de entrada recibe las entradas iniciales. Las capas Ocultas procesan la información recibida de la capa de entrada a través de múltiples niveles de abstracción. Finalmente la capa de salida produce el resultado final del procesamiento.

Las redes neuronales artificiales aprenden a partir de datos. Se les proporciona un conjunto de datos de entrenamiento que incluye ejemplos y sus salidas deseadas. A través de un proceso iterativo llamado aprendizaje supervisado, la red ajusta los pesos de las conexiones para minimizar el error entre sus predicciones y las salidas deseadas.

Funcionamiento

El algoritmo Backpropagation es uno de los algoritmos más comunes para entrenar una red neuronal. El funcionamiento de una red neuronal artificial backpropagation puede ser descrito en tres pasos principales:

1. Entrenamiento: El proceso de ajustar los pesos de las conexiones entre neuronas basado en un conjunto de datos de entrenamiento. Utiliza algoritmos como el gradiente

Algorithm 1 Algoritmo de Entrenamiento de Red Neuronal (Backpropagation)**Entradas:** Conjunto de datos de entrenamiento (X, y) , número de capas ocultas L , tamaño de la capa oculta N , tasa de aprendizaje η **Salidas:** Red neuronal entrenada**Paso 1: Inicialización de pesos y sesgos**

Inicializar pesos y sesgos aleatoriamente para todas las capas

Paso 2: Propagación hacia adelante (Forward Propagation)**for** cada ejemplo de entrenamiento (x_i, y_i) **do**

Calcular la salida de la red neuronal mediante propagación hacia adelante

end;**Paso 3: Retropropagación del error (Backpropagation)****for** cada ejemplo de entrenamiento (x_i, y_i) **do**

Calcular el error de predicción usando la función de pérdida

Actualizar los pesos y sesgos utilizando retropropagación para minimizar el error

end;**Paso 4: Actualización de pesos y sesgos**Actualizar pesos y sesgos utilizando la tasa de aprendizaje η **Paso 5: Repetir hasta convergencia o número de épocas**Repetir el proceso de propagación hacia adelante y retropropagación hasta que se alcance la convergencia o el número máximo de épocas

descendente y el retropropagación para minimizar el error entre la salida prevista y la salida real.

2. Propagación hacia Adelante: El proceso de pasar las entradas a través de la red y obtener una salida.
3. Retropropagación: La técnica para ajustar los pesos mediante la propagación del error desde la salida hasta la entrada, permitiendo a la red aprender.

Las principales ventajas de las redes neuronales artificiales son su capacidad de aprender de grandes cantidades de datos, además de su habilidad para manejar problemas complejos y no lineales. Las redes neuronales artificiales mejoran su rendimiento con el tiempo a medida que aprenden más datos.

Sin embargo, las principales desventajas es que estas requieren grandes cantidades de datos para entrenarse efectivamente, pueden ser computacionalmente costosas de entrenar, estas se considera que son una caja negra que su proceso de toma de decisiones no siempre es fácil de interpretar. La investigación en redes neuronales artificiales es un campo en constante evolución. Con el desarrollo continuo de nuevas arquitecturas y técnicas de entrenamiento, las redes neuronales artificiales desempeñan un papel cada vez más importante en diversos campos de la tecnología y la ciencia. La Figura 2.1 muestra una red neuronal convolucional con capa de entrada, capa de salida y tres capas ocultas.

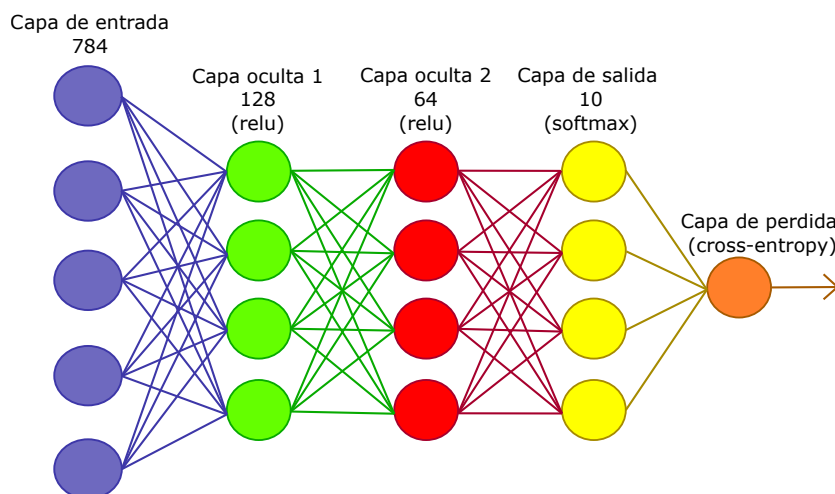


Figura 2.1: Red neuronal convolucional

2.1.2. Support Vector Machines

Las Máquinas de Vectores de Soporte (SVM, por sus siglas en inglés, Support Vector Machines) son un conjunto poderoso de algoritmos de aprendizaje supervisado utilizados principalmente para problemas de clasificación y regresión. Fueron desarrolladas por Vladimir Vapnik y su equipo a principios de la década de 1990 y desde entonces han sido ampliamente utilizadas en diversos campos debido a su efectividad y versatilidad [5] [3].

El principio fundamental de las SVM radica en encontrar un hiperplano óptimo en un espacio dimensional superior que pueda separar de manera óptima las clases en un conjunto de datos. Esto es particularmente útil cuando los datos no son linealmente separables en su espacio original, ya que las SVM pueden emplear funciones kernel para mapear los datos a un espacio dimensional superior donde la separación lineal es posible.

Las principales características de las SVM se enumeran a continuación:

1. Margen Máximo: SVM busca encontrar un hiperplano que maximice el margen entre las clases más cercanas. Estas instancias más cercanas se denominan vectores de soporte, de ahí el nombre del algoritmo.
2. Uso de Kernels: Los kernels permiten a las SVM manejar eficientemente problemas no lineales al mapear los datos a un espacio dimensional superior donde la separación lineal es factible. Algunos ejemplos comunes de kernels incluyen el kernel lineal, el kernel radial (RBF) y el kernel polinomial.
3. Regularización: SVM utiliza un parámetro de regularización (C) para controlar el trade-off entre el error de clasificación y la complejidad del modelo. Un valor alto de C permite clasificar correctamente la mayoría de las muestras de entrenamiento, a expensas de un posible sobreajuste.

Las principales ventajas de las SVM son su efectividad en espacios de alta dimensionalidad: Las SVM son eficaces incluso en espacios de características altamente dimensionales, como en el procesamiento de imágenes o en la clasificación de texto. Además las SVM son muy versátiles pues pueden manejar tanto problemas de clasificación lineales como no lineales mediante el uso adecuado de funciones kernel. Otra importante característica es

Algorithm 2 Algoritmo de Máquinas de Vectores de Soporte (SVM)

Entradas: Conjunto de datos de entrenamiento (X, y) **Salidas:** Hiperplano óptimo y clasificador SVM**Paso 1: Selección del kernel y parámetros**

Seleccionar kernel (lineal, RBF, polinomial, etc.) y otros parámetros

Paso 2: Optimización del margen

Resolver el problema de optimización para encontrar el hiperplano que maximiza el margen

Paso 3: Clasificador SVM**for** cada clase c en y **do**Entrenar un clasificador binario SVM para la clase c utilizando los vectores de soporte**Paso 4: Predicción**Nuevo dato X_{nuevo} Etiqueta de clase predicha \hat{y} Predecir la clase \hat{y} utilizando el clasificador SVM entrenado

que las SVM incorporan un mecanismo natural de regularización, lo que ayuda a prevenir el sobreajuste. Tal vez su gran desventaja se deba a que tienen problemas al trabajar con grandes conjuntos de datos, sin embargo los algoritmos desarrollados en los últimos años pueden trabajar con conjuntos de datos de mediano y gran tamaño. La Figura 2.2 muestra como es maximizada la frontera de decisión en una SVM.

En resumen, las Máquinas de Vectores de Soporte son algoritmos potentes y versátiles que se destacan en problemas donde se necesita una separación clara y efectiva entre clases, especialmente en conjuntos de datos complejos o de alta dimensionalidad. Su capacidad para manejar tanto problemas lineales como no lineales, junto con su eficacia demostrada en una variedad de aplicaciones prácticas, las convierte en una herramienta fundamental en el campo del aprendizaje automático supervisado.




Figura 2.2: Optimización de frontera de decisión con una SVM

2.1.3. Clasificación Bayesiana

El clasificador Bayesiano "Naive Bayes" es un método de clasificación basado en la probabilidad, que aplica el teorema de Bayes con la suposición de independencia entre los predictores. Es especialmente útil para grandes conjuntos de datos y es conocido por su simplicidad y eficacia [25].

Dado un conjunto de características $\mathbf{x} = (x_1, x_2, \dots, x_n)$ y una clase C , el Teorema de Bayes nos da la probabilidad posterior $P(C|\mathbf{x})$ como:

$$P(C|\mathbf{x}) = \frac{P(\mathbf{x}|C) \cdot P(C)}{P(\mathbf{x})}$$

Donde:

- $P(C|\mathbf{x})$ es la probabilidad posterior de que la instancia pertenezca a la clase C dado el vector de características \mathbf{x} .
- $P(\mathbf{x}|C)$ es la probabilidad de observar el vector de características \mathbf{x} dado que la instancia pertenece a la clase C .
- $P(C)$ es la probabilidad previa de la clase C .
- $P(\mathbf{x})$ es la probabilidad de observar el vector de características \mathbf{x} en general.

El término "naive" se refiere a la suposición ingenua de que las características/predictores son independientes entre sí, lo cual rara vez es cierto en la práctica, pero simplifica enormemente los cálculos.

Para clasificar una instancia nueva, el clasificador calcula la probabilidad de que la instancia pertenezca a cada clase posible y selecciona la clase con la mayor probabilidad.

Una de las principales ventajas de este clasificador es que es fácil de implementar, eficiente con grandes conjuntos de datos y requiere menos datos de entrenamiento.

Sin embargo, la suposición de independencia rara vez es verdadera en la vida real. Otra desventaja importante radica en que no puede capturar relaciones entre características.

El clasificador Bayesiano Naive es una herramienta poderosa y sencilla que se puede aplicar a una variedad de problemas de clasificación, siempre y cuando se tenga en cuenta

sus limitaciones y se utilice de manera adecuada. La Figura 2.3 muestra un conjunto de datos y las probabilidades condicionales de sus características.




Figura 2.3: Clasificador Bayes

Algoritmo

Entrada

- Un conjunto de entrenamiento $D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\}$ donde \mathbf{x}_i es un vector de características y y_i es la clase correspondiente.

Salida

- Un modelo que predice la clase y de una nueva instancia \mathbf{x} .

Pasos del Algoritmo

1. Calcular las probabilidades previas para cada clase C_k :

$$P(C_k) = \frac{|\{y_i = C_k\}|}{m}$$

donde $|\{y_i = C_k\}|$ es el número de instancias en el conjunto de entrenamiento que pertenecen a la clase C_k y m es el número total de instancias.

2. Calcular las probabilidades condicionales para cada característica dado cada clase:

$$P(x_i|C_k) = \frac{|\{x_i \in \mathbf{x} | y = C_k\}| + \alpha}{|\{y = C_k\}| + \alpha n}$$

donde α es un parámetro de suavizado (Laplace smoothing) y n es el número de valores posibles de x_i .

3. Para una nueva instancia $\mathbf{x} = (x_1, x_2, \dots, x_n)$, calcular la probabilidad posterior para cada clase:

$$P(C_k|\mathbf{x}) \propto P(C_k) \cdot \prod_{i=1}^n P(x_i|C_k)$$

4. Asignar la clase con la mayor probabilidad posterior:

$$y = \arg \max_{C_k} P(C_k|\mathbf{x})$$

2.1.4. Árboles de decisión

Un clasificador de árbol de decisión es un modelo de aprendizaje automático utilizado para la clasificación y regresión. Su estructura es similar a la de un árbol, donde cada nodo interno representa una característica del conjunto de datos, cada rama representa un resultado de la prueba de esa característica, y cada nodo hoja representa una etiqueta de clase (en el caso de clasificación) o un valor continuo (en el caso de regresión) [18].

El proceso para construir un árbol de decisión puede resumirse en los siguientes pasos y este es resumido en el algoritmo 3:

1. Selecciona la característica que mejor divide el conjunto de datos en términos de homogeneidad de la clase. Esto se puede hacer utilizando métricas como la ganancia de información, el índice de Gini, o la reducción de varianza.
2. Divide el conjunto de datos en subconjuntos basados en la mejor característica seleccionada. Cada subconjunto corresponde a uno de los posibles valores de esa característica.
3. Aplica el mismo proceso recursivamente en cada subconjunto. La recursión se detiene cuando uno de los siguientes criterios se cumple:
 - Todos los ejemplos en un subconjunto pertenecen a la misma clase.
 - No hay más características para dividir los datos.

- Se alcanza una profundidad máxima predefinida del árbol.
4. Las hojas del árbol se etiquetan con la clase que más aparece entre los ejemplos del subconjunto correspondiente.

Las ventajas más importantes de los árboles de decisión son su simplicidad e interpretabilidad. Los árboles de decisión son fáciles de entender y visualizar. Las reglas de decisión pueden interpretarse fácilmente, lo cual es valioso para la interpretación del modelo y la toma de decisiones. Otra ventaja importante es que los árboles de decisión no requieren la normalización de los datos o escalado de las características. Además, los árboles de decisión pueden manejar tanto características categóricas como numéricas y son menos sensibles a los valores atípicos en los datos. La Figura 2.4 muestra un ejemplo de un árbol de decisión con variables categóricas, nodos de decisión y nodos de hojas.

Sin embargo su principal desventaja radica en que pueden crear modelos demasiado complejos que no generalizan bien a nuevos datos. Esto se puede mitigar mediante técnicas como la poda del árbol, el establecimiento de una profundidad máxima, o el uso de algoritmos de ensamble como Random Forest. Otra desventaja es que pequeños cambios en los datos pueden resultar en árboles muy diferentes, lo que puede ser mitigado con técnicas de ensamble.

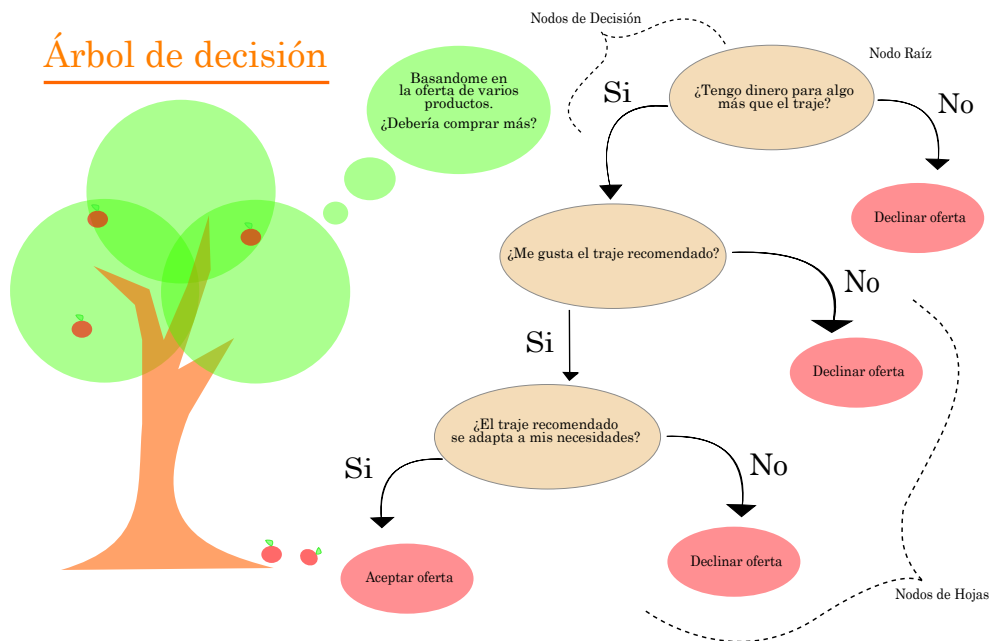


Figura 2.4: Árbol de decisión

2.2. Técnicas de Evaluación de desempeño

Las técnicas de evaluación de desempeño de clasificadores en sistemas de visión artificial y aprendizaje automático son fundamentales para medir la eficacia y eficiencia de los modelos. A continuación, se describen algunas de las técnicas más comunes, junto con sus ventajas y desventajas [7].

2.2.1. Matriz de Confusión

La matriz de confusión es una tabla que permite visualizar el rendimiento de un modelo de clasificación. Muestra las predicciones correctas e incorrectas desglosadas por cada clase. Los componentes clave son Verdaderos Positivos (VP), Falsos Positivos (FP), Verdaderos Negativos (VN) y Falsos Negativos (FN)

La matriz de confusión proporciona una visión detallada del rendimiento del modelo en cada clase y es muy importante para calcular otras métricas de desempeño como precisión,

Algorithm 3 Algoritmo ID3

Entradas: Conjunto de datos D , Características A , Targets T **Salidas:** Árbol de decisión**if** todos los ejemplos en D están en una clase **then****return** una hoja con esa clase**if** A está vacío **then****return** una hoja con la clase mayoritaria en D Seleccionar característica $a \in A$ que mejor clasifique los ejemplos (mayor ganancia de información) Crear un nodo raíz etiquetado con a **for** cada valor posible v de a **do**Sea D_v el subconjunto de D donde la característica a tiene valor v **if** D_v está vacío **then**Añadir una hoja al árbol con la clase mayoritaria en D **else** Añadir el subárbol $\text{ID3}(D_v, A \setminus \{a\}, T)$ al árbol**return** el nodo raíz

sensibilidad, especificidad y F1-score [12] [22] [13].

2.2.2. Precisión

La Precisión es la proporción de predicciones correctas entre el total de predicciones positivas. Es decir, se puede identificar los valores positivos clasificados correctamente:

$$precision = \frac{TP}{TP + FP} \quad (2.1)$$

2.2.3. Recall (Sensibilidad)

La sensibilidad se define como la proporción de verdaderos positivos entre el total de verdaderos positivos y falsos negativos.

$$recall = \frac{TP}{TP + FN} \quad (2.2)$$

Estas métricas facilitan la evaluación de la relevancia de las predicciones positivas. La precisión y el recall (sensibilidad) pueden ser manipulados, mejorando uno a costa del otro.

2.2.4. F1-Score

El F1-score es la media armónica de la precisión y la sensibilidad. Combina estas dos métricas en un solo valor para balancear su impacto.

$$F1 = \left(\frac{precision^{-1} \cdot recall^{-1}}{2} \right)^{-1} = \frac{2precision * recall}{precision + recall} \quad (2.3)$$

El mejor valor para F es cuando da resultado 1, lo que significa que la tasa de aciertos para la precisión y exhaustividad son perfectas; 0 para la peor clasificación.

Esta métrica es útil cuando se necesita un balance entre precisión y recall, proporciona una métrica única y comprensible para evaluar el rendimiento del modelo. Sin embargo, puede no reflejar adecuadamente el desempeño si las clases están desbalanceadas. La

Figura muestra diferentes métricas de desempeño usadas comúnmente en reconocimiento de patrones [6].

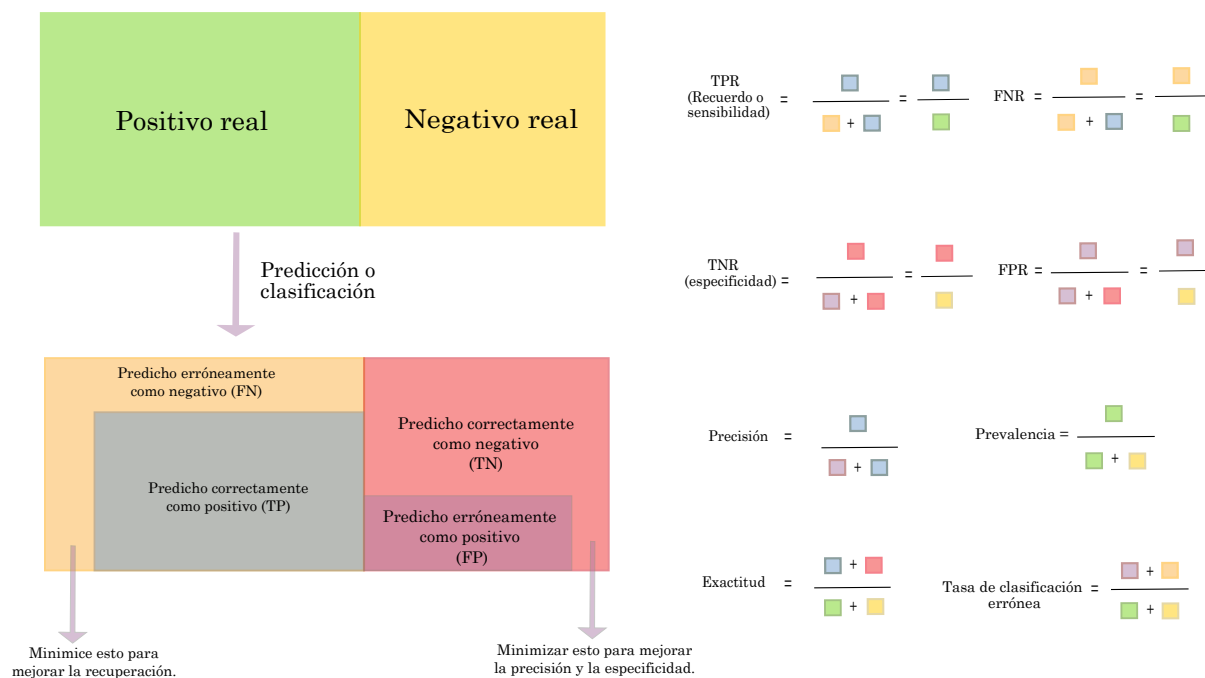


Figura 2.5: Diferentes métricas de desempeño

2.2.5. Curva ROC y AUC (Área Bajo la Curva)

La curva ROC (Receiver Operating Characteristic) traza la tasa de verdaderos positivos contra la tasa de falsos positivos con diferentes umbrales de decisión. El área bajo la curva (AUC) es un resumen del rendimiento en toda la gama de umbrales utilizados.

Esta métrica proporciona una visión completa del rendimiento del modelo. Sin embargo, puede ser menos informativa en conjuntos de datos desbalanceados y la interpretación de la curva ROC puede ser compleja. La Figura 2.6 muestra la interpretación de diferentes gráficas AUC-ROC [19].

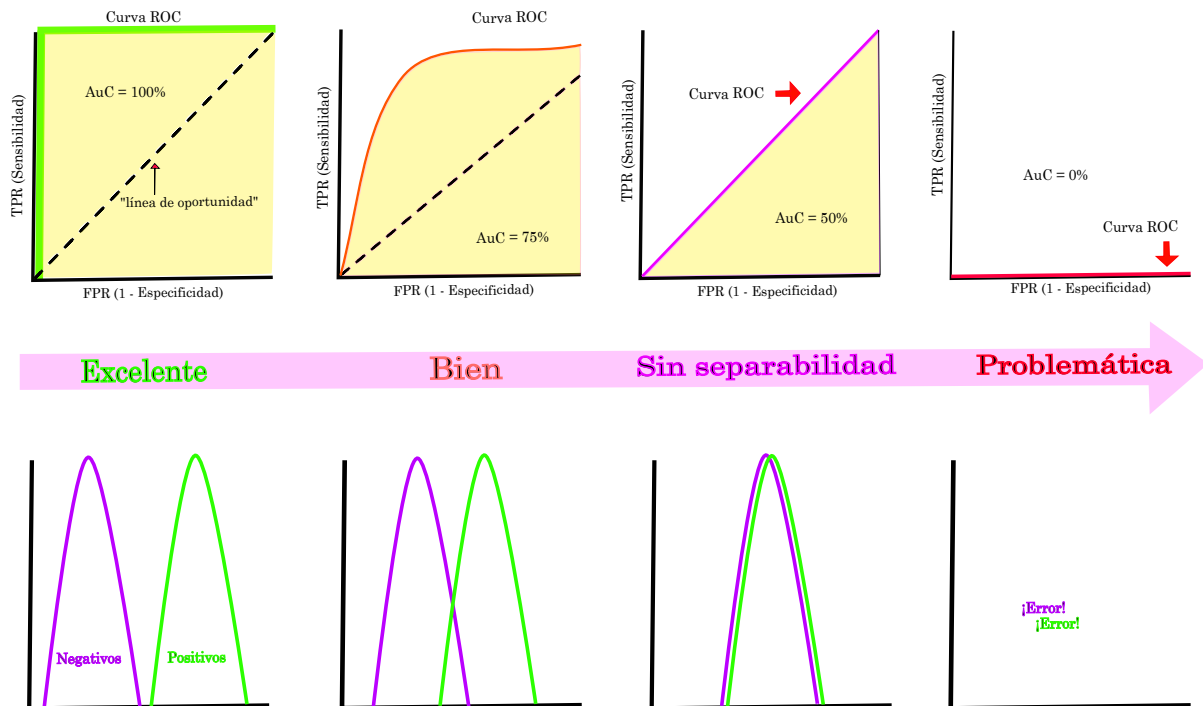


Figura 2.6: Interpretación de AUC-ROC

2.2.6. Exactitud (Accuracy)

La exactitud es la proporción de predicciones correctas (tanto verdaderos positivos como verdaderos negativos) entre el total de predicciones.

$$recall = \frac{TP + TN}{TP + FN} \quad (2.4)$$

Esta métrica es fácil de interpretar y calcular, además esta es muy útil para problemas con clases balanceadas.

2.3. Validación Cruzada

La validación cruzada es una técnica utilizada para evaluar la capacidad de generalización de un modelo de aprendizaje automático. Consiste en dividir los datos disponibles en múltiples subconjuntos. El proceso se repite varias veces, y cada vez un subconjunto diferente se utiliza como conjunto de prueba mientras el resto se utiliza para entrenar el modelo. Los resultados se promedian para obtener una estimación más robusta del rendimiento del modelo.

2.3.1. Tipos más comunes de Validación Cruzada

k-Fold Cross-Validation

Los datos se dividen en k partes o folds. El modelo se entrena k veces, cada vez utilizando un fold diferente como conjunto de prueba y los $k - 1$ restantes como conjunto de entrenamiento. Esta técnica proporciona una buena estimación del rendimiento del modelo, utiliza todos los datos para la validación, y es menos sesgado que dividir los datos una sola vez. Pero puede ser computacionalmente costoso si k es grande.

Leave-One-Out Cross-Validation (LOOCV)

Una versión extrema de k-Fold donde k es igual al número de instancias en el conjunto de datos. Cada instancia se utiliza una vez como conjunto de prueba y el resto como conjunto de entrenamiento. Esta técnica utiliza la máxima cantidad de datos posibles para el entrenamiento. Sin embargo, puede ser muy costoso computacionalmente para grandes conjuntos de datos. La Figura 2.7 muestra la técnica de validación cruzada con $k = 5$.

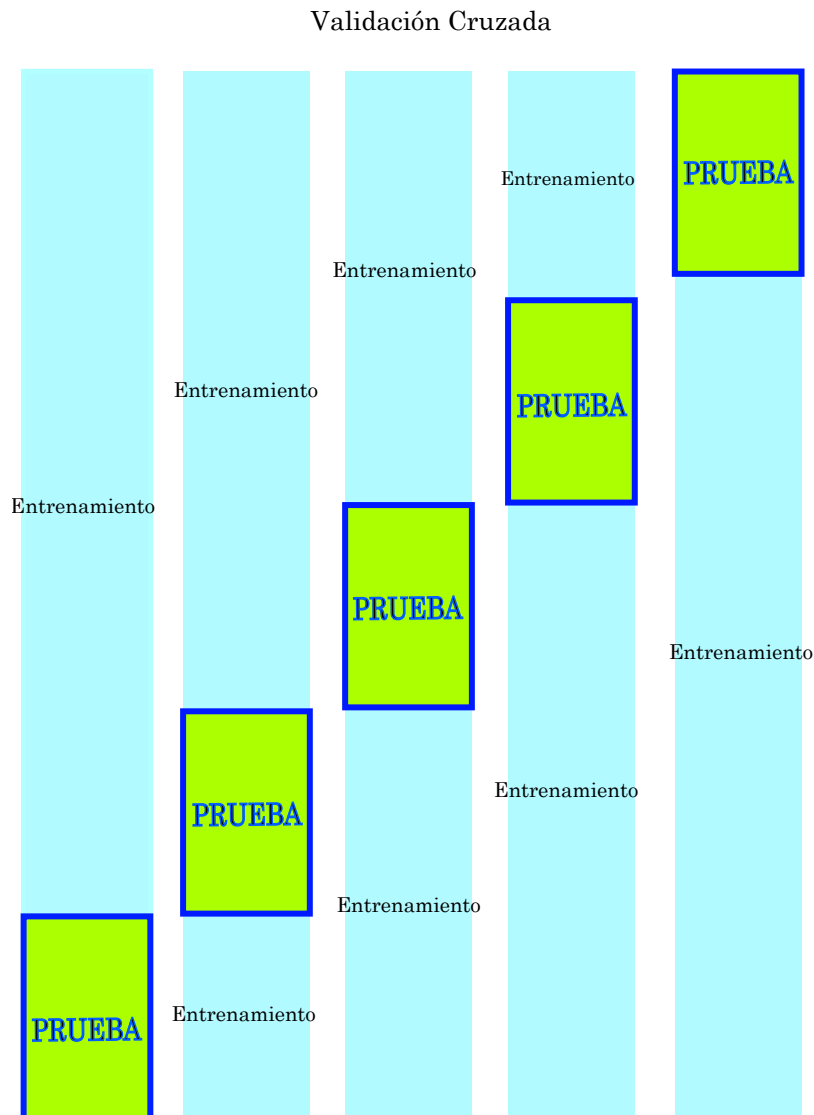


Figura 2.7: Validación cruzada con $k = 5$

2.4. Técnicas de segmentación

La segmentación de imágenes es un proceso fundamental en el campo del procesamiento de imágenes y visión por computadora. Su objetivo principal es dividir una imagen en regiones o segmentos que son homogéneos en cuanto a ciertos criterios, como el color, la intensidad o la textura. Cada uno de estos segmentos representa una porción significativa

de la imagen, como objetos, formas o áreas específicas.

El objetivo de la segmentación de imágenes es simplificar y cambiar la representación de una imagen para hacerla más significativa y fácil de analizar. Esto es crucial en numerosas aplicaciones.

Existen varias técnicas de segmentación de imágenes, cada una adecuada para diferentes tipos de imágenes y aplicaciones. Algunas de las más comunes incluyen:

1. Segmentación por umbral: Divide la imagen según los valores de intensidad de los píxeles. Un ejemplo es el método de Otsu, que determina un umbral óptimo para separar objetos del fondo.
2. Segmentación basada en regiones: Agrupa píxeles adyacentes con características similares, como el algoritmo de crecimiento de regiones.
3. Segmentación por bordes: Detecta discontinuidades en la intensidad de la imagen para identificar los límites de los objetos.
4. Métodos basados en clustering: Agrupan píxeles en clusters según características comunes, como el algoritmo k-means.

2.5. Técnicas de Extracción de características

El uso de visión artificial se ha extendido en los últimos años a múltiples aplicaciones. La extracción de características es un proceso dentro de vision artificial, esta se enfoca en seleccionar información relevante de las imágenes, facilitando el aprendizaje automático y mejorando la interpretación por parte de los humanos. A continuación, se describen algunas de las técnicas de extracción de características más comúnmente utilizadas.

2.5.1. Características texturales de Haralick

Las características texturales de Haralick son un conjunto de descriptores utilizados para analizar la textura de imágenes. Estas características fueron propuestas por Robert M. Haralick en 1973 y se basan en la matriz de co-ocurrencia de niveles de gris (GLCM,

por sus siglas en inglés). La GLCM es una matriz que describe la frecuencia con la que ciertos pares de píxeles, con valores de gris específicos, ocurren en una imagen en una orientación y distancia definidas. A partir de esta matriz, se pueden calcular diversas características texturales. .

Los descriptores de Haralick utilizados son mostrados a continuación:

1. Energía (Segundo Momento Angular): Mide la uniformidad de la textura. Un valor alto indica poca variabilidad en la textura.
2. Contraste: Evalúa la cantidad de variación local en la imagen. Valores altos indican una textura con alto contraste.
3. Correlación: Mide la similitud de los elementos de la GLCM con respecto a la diagonal. Un valor alto indica una fuerte relación lineal entre los píxeles.
4. Varianza: Mide la dispersión de los valores de gris alrededor de la media.
5. Inverso de la Diferencia de Momento (Homogeneidad): Evalúa la proximidad de la distribución de la GLCM a la diagonal. Valores altos indican que los píxeles cercanos tienen valores similares.
6. Suma Promedio: Suma de los promedios de las filas y columnas de la GLCM.
7. Suma Varianza: Varianza de la suma de las filas y columnas de la GLCM.
8. Suma Entropía: Mide la entropía (desorden) de la suma de las filas y columnas de la GLCM.
9. Entropía: Evalúa la aleatoriedad de los valores de gris. Valores altos indican una textura muy compleja.
10. Diferencia de Varianza: Varianza de la diferencia de las filas y columnas de la GLCM.
11. Diferencia de Entropía: Entropía de la diferencia de las filas y columnas de la GLCM.
12. Medidas de Correlación 1 y 2: Miden la relación entre las entradas de la GLCM y su varianza.

Estas características texturales son ampliamente utilizadas en el análisis de imágenes para tareas como la clasificación de texturas, segmentación de imágenes y reconocimiento de patrones. La Figura 2.8 muestra la extracción de características usando la matriz de coocurrencia.

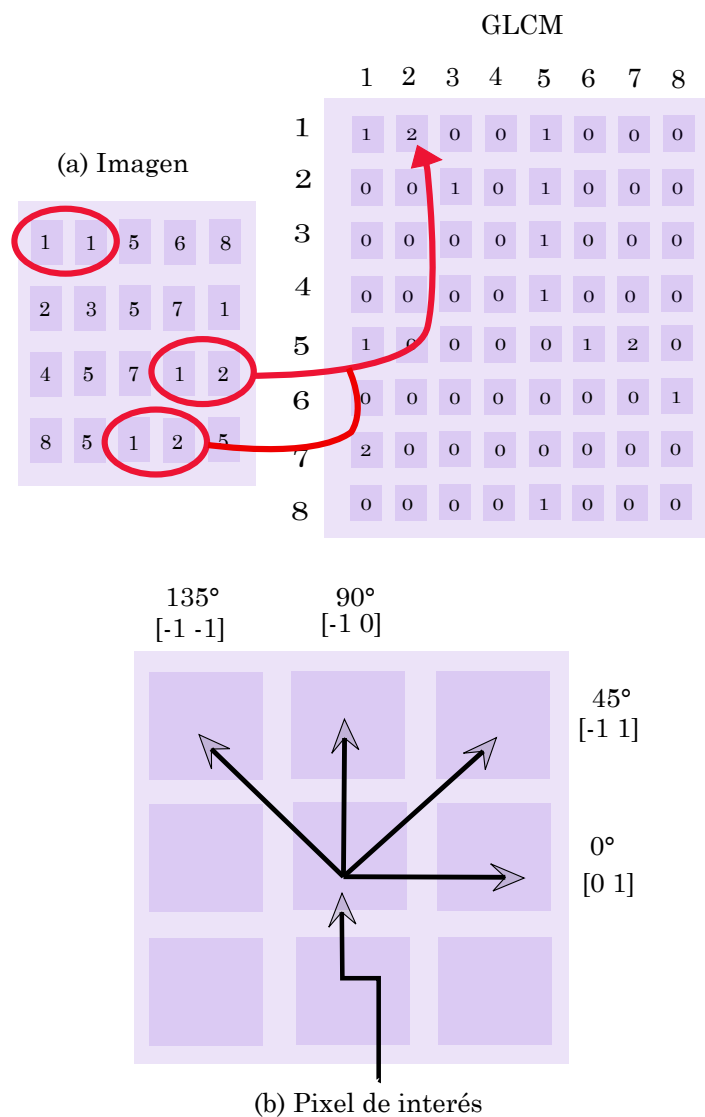


Figura 2.8: Extracción de características usando la matriz de coocurrencia

2.5.2. Patrones binarios locales

Los Patrones Binarios Locales (LBP, por sus siglas en inglés) son una técnica ampliamente utilizada en el análisis de imágenes para describir la textura. Introducidos por Timo Ojala en 1996, los LBP son una herramienta eficaz para la clasificación y análisis de texturas debido a su simplicidad computacional y robustez frente a cambios de iluminación.

El cálculo de LBP en una imagen se realiza de la siguiente manera:

1. Selección de un píxel central: Se selecciona un píxel en la imagen, denominado píxel central.
2. Comparación con los píxeles vecinos: Se comparan los valores de gris del píxel central con los de sus píxeles vecinos en una vecindad definida (normalmente una vecindad 3x3).
3. Asignación de bits: Si el valor del píxel vecino es mayor o igual al del píxel central, se asigna un bit '1'; de lo contrario, se asigna un bit '0'.
4. Formación de un número binario: Los bits resultantes se concatenan para formar un número binario.
5. Conversión a decimal: El número binario se convierte a un valor decimal, que representa el valor LBP del píxel central.

Los Patrones Binarios Locales son una técnica poderosa y versátil en el procesamiento y análisis de imágenes, proporcionando una descripción compacta y robusta de la textura de una imagen. La Figura 2.9 muestra la técnica para extracción de características LBP.

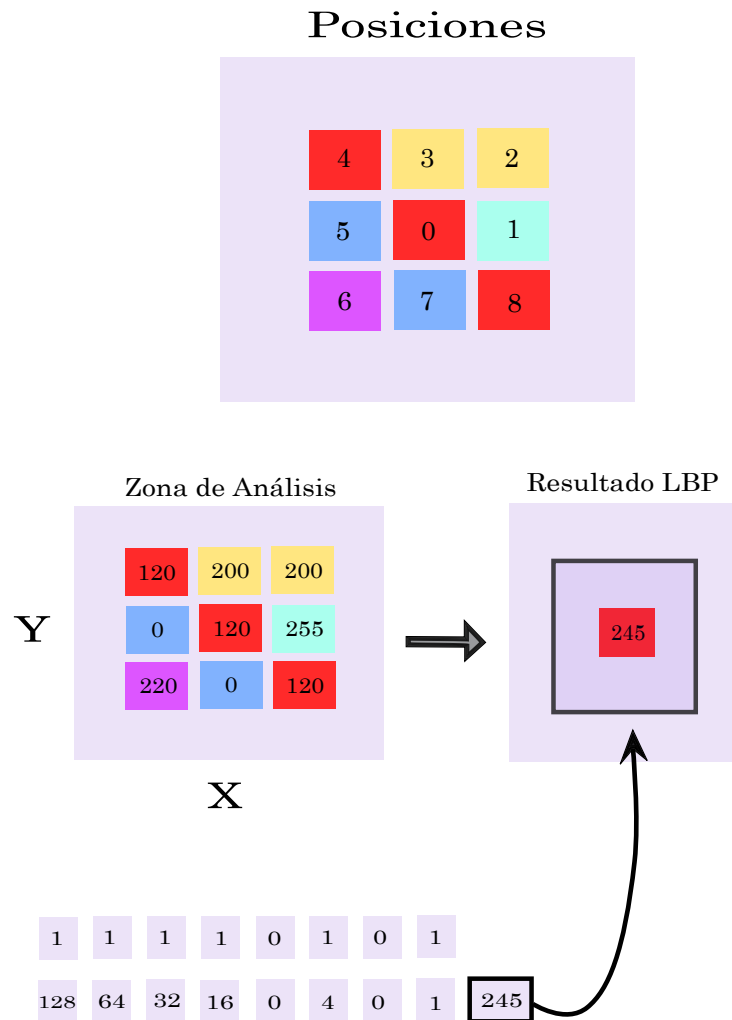


Figura 2.9: Algoritmo LBP

2.6. Histograma de Gradientes Ordenados

El Histograma de Gradientes Orientados (HOG, por sus siglas en inglés) es una técnica de extracción de características utilizada principalmente en el procesamiento y análisis de imágenes para la detección de objetos. Esta técnica se basa en la distribución de intensidades de gradiente o direcciones de borde de una imagen. HOG es particularmente efectivo en la detección de formas y estructuras, siendo ampliamente utilizado en la detección de peatones y reconocimiento de objetos.

El principio básico del HOG es la descripción de la forma y apariencia de objetos

mediante la distribución de gradientes locales. Los gradientes se calculan sobre pequeñas regiones de la imagen llamadas celdas, y luego se agrupan en bloques para normalizar la iluminación y contraste.

El cálculo de HoG en una imagen se realiza de la siguiente manera:

1. La imagen se preprocesa, generalmente convirtiéndola a escala de grises si no lo está.
2. Los gradientes se calculan utilizando filtros de derivada como el operador de Sobel. Para cada píxel, se obtienen dos componentes del gradiente: la magnitud y la orientación.
3. La imagen se divide en celdas de tamaño fijo (por ejemplo, 8x8 píxeles).
4. En cada celda, se construye un histograma de orientaciones de gradiente. Las orientaciones se agrupan en bins (por ejemplo, 9 bins para un rango de 0 a 180 grados).
5. Cada píxel contribuye al histograma con su magnitud de gradiente, asignada al bin correspondiente a su orientación.
6. Las celdas se agrupan en bloques superpuestos (por ejemplo, bloques de 2x2 celdas).
7. Los histogramas de las celdas en cada bloque se concatenan y normalizan para reducir los efectos de variaciones de iluminación y contraste.
8. Los histogramas normalizados de todos los bloques se concatenan para formar un vector de características final que describe la imagen o región de interés.

El Histograma de Gradientes Orientados es una técnica poderosa y ampliamente utilizada en el análisis de imágenes y la visión por computadora, proporcionando descripciones robustas y detalladas de las formas y estructuras en las imágenes.

2.6.1. Características cromáticas

Las características cromáticas son atributos relacionados con el color de una imagen. Estas características son fundamentales en el procesamiento de imágenes y la visión por

computadora, ya que permiten la identificación, clasificación y seguimiento de objetos en función de sus colores. Las características cromáticas se pueden extraer utilizando diversos modelos de color y técnicas de análisis.

Las técnicas de Extracción de Características Cromáticas más comunes se enumeran a continuación:

1. **Histograma de color:** Un histograma de color mide la distribución de colores en una imagen. Se crea contando el número de píxeles de cada color en la imagen.
2. **Correlograma de Color:** Un correlograma de color extiende el histograma de color al capturar la correlación espacial de colores.
3. **Momento de Color:** Los momentos de color (media, varianza y sesgo) se utilizan para describir la distribución de colores en una imagen.
4. **Segmentación de Color:** La segmentación de color implica dividir una imagen en regiones basadas en colores similares.
5. **Descriptores de Color Locales:** Los descriptores de color locales (como SIFT, SURF adaptados al color) se utilizan para capturar la información de color en pequeñas regiones de la imagen.

Los extractores de características cromáticas son fáciles de interpretar y utilizar. Los colores pueden proporcionar una manera rápida de segmentar y clasificar objetos en una imagen. Además, los colores pueden ser menos afectados por cambios en la forma y textura del objeto.

Sin embargo, las características cromáticas pueden cambiar drásticamente con diferentes condiciones de iluminación. Además, los colores similares pueden ser difíciles de distinguir, especialmente en entornos complejos.

Las características cromáticas son herramientas poderosas en el análisis de imágenes y la visión por computadora, permitiendo una amplia variedad de aplicaciones desde la detección y clasificación de objetos hasta la mejora y segmentación de imágenes.

Capítulo 3

Técnicas de selección de características

La selección de características es un paso crucial en el procesamiento de datos y el aprendizaje automático, ya que permite reducir la dimensionalidad del conjunto de datos, mejorar la eficiencia de los modelos y aumentar la precisión al eliminar características irrelevantes o redundantes.

Aunque en la actualidad existe un gran número de técnicas de selección de características. En esta tesis solo experimentaremos con Selección hacia adelante, eliminación hacia atrás y algoritmos genéticos para selección de características.

3.1. Selección hacia adelante

La selección hacia adelante (Forward Selection) es una técnica de selección de características utilizada en el campo del aprendizaje automático y la estadística para identificar el subconjunto óptimo de características que mejora el rendimiento de un modelo predictivo. Esta técnica es una estrategia de búsqueda heurística que agrega características al modelo de forma incremental [11] [14] [15].

Aunque el procedimiento del algoritmo puede verse en el algoritmo 4 a continuación se describe en detalle:

1. El algoritmo inicia con un modelo que no incluye ninguna característica (modelo vacío).

2. Se evalúa el rendimiento del modelo añadiendo cada característica individualmente.


3. Selecciona la característica que, al ser agregada, produce la mayor mejora en el rendimiento del modelo según una métrica específica (por ejemplo, precisión, error cuadrático medio, etc.).

4. Añade la característica seleccionada al modelo.

5. Repite los pasos 2 y 3, evaluando el rendimiento del modelo con cada nueva característica adicional y seleccionando la que ofrece la mayor mejora.


El proceso se detiene cuando no hay más mejoras significativas en el rendimiento del modelo, o cuando se ha alcanzado un número predefinido de características. La Figura 3.1 muestra el proceso de selección de características hacia adelante.

Comience con un modelo sin variables
Un modelo nulo con variable cero



Sumando las variables más significativas según
 Valor p más pequeño para la prueba F del modelo en su conjunto
 Mayor aumento en R^2 , o
 Mayor caída en la Suma de Cuadrados de Residuales del modelo
 en comparación con las otras variables consideradas.

Un modelo con dos variables.



Continúe agregando las variables más significativas
 hasta llegar a la regla de detención o quedarse sin variables.

Un modelo con cuatro variables




Figura 3.1: Selección de características Hacia Adelante

Algorithm 4 Selección Hacia Adelante (Forward Selection)

```

1: Input: Conjunto de datos  $D$  con  $n$  características, criterio de parada  $S$ 
2: Output: Subconjunto de características seleccionadas  $F$ 
3:  $F \leftarrow \emptyset$  ▷ Inicializar el conjunto de características seleccionadas
4:  $R \leftarrow \{X_1, X_2, \dots, X_n\}$  ▷ Conjunto de todas las características
5:  $best\_score \leftarrow 0$ 
6: while Criterio de parada  $S$  no alcanzado do
7:    $current\_best\_feature \leftarrow \emptyset$ 
8:    $current\_best\_score \leftarrow best\_score$ 
9:   for all  $X_i \in R$  do
10:      $temp\_model \leftarrow$  Entrenar modelo con  $F \cup \{X_i\}$ 
11:      $score \leftarrow$  Evaluar rendimiento de  $temp\_model$ 
12:     if  $score > current\_best\_score$  then
13:        $current\_best\_feature \leftarrow X_i$ 
14:        $current\_best\_score \leftarrow score$ 
15:     end if
16:   end for
17:   if  $current\_best\_feature \neq \emptyset$  then
18:      $F \leftarrow F \cup \{current\_best\_feature\}$ 
19:      $R \leftarrow R \setminus \{current\_best\_feature\}$ 
20:      $best\_score \leftarrow current\_best\_score$ 
21:   else
22:     break ▷ No hay mejora en el rendimiento, terminar
23:   end if
24: end while
25: return  $F$ 

```

3.2. Eliminación hacia atrás

La eliminación hacia atrás es una técnica de selección de características utilizada en el aprendizaje automático y la minería de datos para mejorar la precisión y eficiencia de los modelos predictivos. El objetivo de esta técnica es identificar y retener solo aquellas características que contribuyen de manera significativa al rendimiento del modelo, eliminando las que son irrelevantes o redundantes [27] [23] [16].

La eliminación hacia atrás comienza con un modelo que incluye todas las características disponibles en el conjunto de datos. Luego, se evalúa el rendimiento del modelo iterativamente, eliminando una característica a la vez. En cada iteración, se elimina la característica que menos afecta negativamente al rendimiento del modelo. Este proceso continúa hasta que se alcanza un criterio de parada, como una mejora mínima en el rendimiento del modelo o hasta que queda una sola característica.

Simplicidad: La técnica es fácil de entender e implementar. **Mejora del Rendimiento:** Al eliminar características irrelevantes, el modelo puede volverse más preciso y generalizable. **Reducción de la Complejidad:** Disminuye el número de características, lo que reduce la complejidad del modelo y el tiempo de procesamiento. **Interpretabilidad:** Con menos características, el modelo es más fácil de interpretar y explicar.

Costosa en Computación: Puede ser computacionalmente intensiva, especialmente con un gran número de características. **Depende del Modelo Inicial:** El rendimiento final puede depender del modelo inicial y de la métrica de evaluación utilizada. **No Escalable:** No es ideal para conjuntos de datos extremadamente grandes con muchas características debido al tiempo y recursos necesarios para evaluar cada posible subconjunto de características. La Figura 3.2 muestra el proceso de eliminación de características hacia atrás.


Aunque el procedimiento del algoritmo puede verse en el algoritmo 5 a continuación se describe en detalle:

1. Comienza con todas las características disponibles en el modelo.
2. Evalúa el rendimiento del modelo con todas las características.
3. Iterativamente elimina la característica que menos afecta el rendimiento del modelo.


- Después de cada eliminación, se reevalúa el rendimiento del modelo.
- Continúa el proceso hasta que se alcance un criterio de parada predefinido.

Ejemplo de selección paso a paso hacia atrás con 5 variables

Comience con un modelo que contenga todas las variables.



Eliminar la variable menos significativa



Sigue eliminando la variable menos significativa hasta que se hayan probado todas las variables.




Figura 3.2: Eliminación de características Hacia Atras

Algorithm 5 Eliminación hacia Atrás para Selección de Características

- 1: **Entrada:** Conjunto de datos con características $\{X_1, X_2, \dots, X_p\}$
 - 2: **Salida:** Subconjunto final de características seleccionadas
 - 3: Inicializar conjunto de características actuales $C \leftarrow \{X_1, X_2, \dots, X_p\}$
 - 4: **while** criterio de parada no satisfecho **do**
 - 5: Ajustar el modelo usando las características en C
 - 6: Evaluar la importancia de cada característica en C
 - 7: Identificar la característica menos significativa en C
 - 8: Eliminar la característica menos significativa de C
 - 9: **end while**
 - 10: **Devolver:** Conjunto de características en C
-

3.3. Algoritmos genéticos para selección de características

Los algoritmos genéticos son una técnica de optimización inspirada en la evolución biológica. Son muy útiles para la selección de características en problemas de aprendizaje automático, donde el objetivo es encontrar un subconjunto óptimo de características que maximice el rendimiento del modelo [9] [21] [17]. El algoritmo es mostrado en 6 y los pasos principales se muestran en detalle a continuación

1. Se genera una población inicial de tamaño N con soluciones aleatorias. Cada individuo en la población es un vector binario de longitud p , donde cada bit indica si una característica está presente (1) o no (0).
2. Se evalúa la aptitud de cada individuo en la población. La aptitud se calcula en función del rendimiento del modelo de aprendizaje automático entrenado con las características seleccionadas por el individuo. Por ejemplo, se puede usar la precisión, el error cuadrático medio o cualquier otra métrica de rendimiento relevante.
3. Se seleccionan padres de la población para la cruce, típicamente usando métodos

como la selección por torneo, la ruleta de selección o la selección por ranking. Los padres seleccionados deben ser aquellos con mayor aptitud, asegurando que las mejores características se transmitan a la siguiente generación.

4. Se realiza la cruce entre pares de padres para generar nuevos hijos. La cruce puede ser de un punto, de dos puntos o uniforme, dependiendo del diseño del algoritmo. Este paso combina las características de los padres para producir una nueva generación de individuos.
5. Se aplica una tasa de mutación m a los hijos. La mutación introduce variabilidad en la población al invertir el valor de algunos bits en el vector binario del individuo, lo cual ayuda a explorar nuevas áreas del espacio de soluciones y a evitar el estancamiento en óptimos locales.
6. Se seleccionan los mejores individuos de entre la población actual y los nuevos hijos para formar la nueva población. Esto puede hacerse combinando las dos poblaciones y seleccionando los individuos con mayor aptitud, o reemplazando directamente a la población actual con los nuevos hijos.
7. Se repiten los pasos de evaluación, selección de padres, cruce, mutación y selección de sobrevivientes durante un número predefinido de generaciones G o hasta que se cumpla un criterio de parada, como la estabilización de la aptitud de la población o un límite de tiempo.
8. Al finalizar el proceso, se devuelve el mejor individuo de la población final. Este individuo representa el subconjunto óptimo de características para el problema de aprendizaje automático en cuestión.

Algorithm 6 Algoritmo Genético para Selección de Características

- 1: **Entrada:** Conjunto de datos con características $\{X_1, X_2, \dots, X_p\}$, tamaño de la población N , tasa de mutación m , número de generaciones G
 - 2: **Salida:** Subconjunto final de características seleccionadas
 - 3: Inicializar la población con soluciones aleatorias de tamaño N
 - 4: **for** $g \leftarrow 1$ G **do**
 - 5: **for** cada individuo en la población **do**
 - 6: Evaluar la aptitud del individuo basado en el rendimiento del modelo con las características seleccionadas
 - 7: **end for**
 - 8: Seleccionar padres para la cruce
 - 9: Realizar cruce para generar nuevos hijos
 - 10: **for** cada hijo **do**
 - 11: Aplicar mutación al hijo con una tasa de mutación m
 - 12: **end for**
 - 13: Seleccionar los mejores individuos para la siguiente generación
 - 14: **end for**
 - 15: Devolver el mejor individuo de la población
-

Capítulo 4

Metodología

En este Capítulo se muestra la metodología para realizar el análisis comparativo entre las diferentes técnicas de selección de características. La fiabilidad y eficiencia del sistema de reconocimiento dependen directamente de la técnicas de selección de características utilizada.

En los experimentos llevados a cabo, se exploraron diversas técnicas de selección de características y se evaluaron diferentes clasificadores. La Figura 4.1 ilustra la metodología desarrollada para los experimentos descritos en esta tesis.

En este Capítulo se muestra la metodología utilizada, en primer lugar, se describe el diseño experimental y la justificación de la metodología empleada. A continuación, se presentan las técnicas y herramientas utilizadas, seguidas de una explicación paso a paso de cómo se aplicaron en el contexto específico de este estudio. Además, se incluyen diagramas y tablas que ilustran los resultados intermedios obtenidos en cada etapa del proceso, lo cual facilita la comprensión del flujo de trabajo. Finalmente, se discuten las posibles limitaciones encontradas y las soluciones implementadas para superarlas, asegurando así la robustez y validez de los hallazgos. Este enfoque detallado no solo garantiza la reproducibilidad del estudio, sino que también permite al lector apreciar la rigurosidad con la que se ha llevado a cabo la investigación.

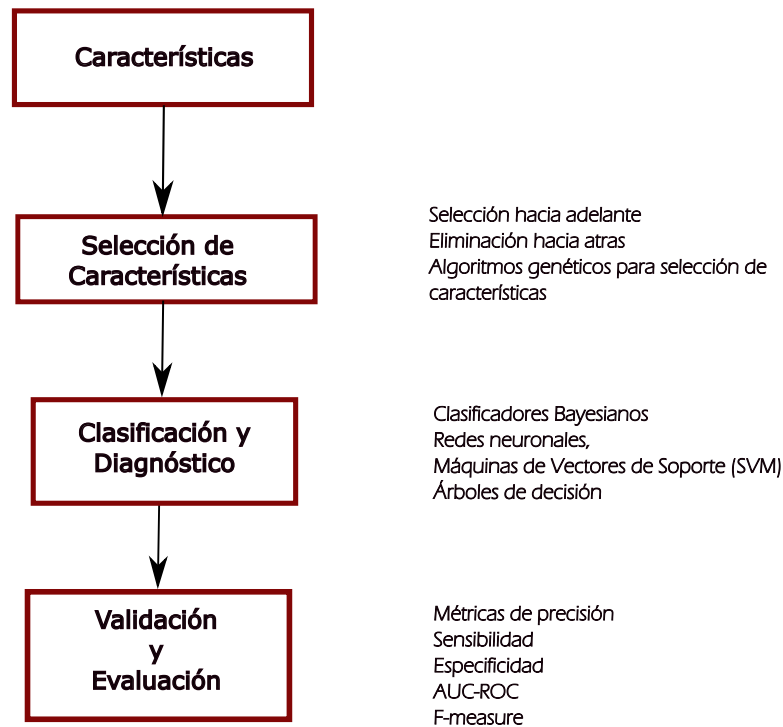


Figura 4.1: Pasos utilizados para realizar el análisis en esta tesis

4.1. Conjunto de datos utilizado

En los experimentos realizados, se utilizaron dos conjuntos de imágenes, el primer conjunto compuesto de tres clases de datos el cual fue obtenido de <https://www5.cs.fau.de/en/our-team/bo-ckruediger/automated-glaucoma-risk-index/>. De acuerdo a sus recopiladores el conjunto fue generado bajo condiciones específicas en un ambiente completamente controlado. 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 4.2: Conjunto de datos utilizado a) Retinopatía diabética b) Glaucoma c) Saludable

El segundo conjunto de datos fue obtenido de ([**Diabetic Retinopathy Image Dataset, 2018**]). El cual está dividido en tres partes:

- A. Segmentación: Consiste de imágenes de fondo de ojo a color (81 imágenes divididas en conjuntos de entrenamiento y prueba). Imágenes de lesiones (microaneurismas, hemorragias, exudados duros y exudados blandos divididos en conjuntos de entrenamiento y prueba) y disco óptico (dividido en conjunto de entrenamiento y prueba)
- B. Clasificación de enfermedades: consiste en Imágenes de fondo de ojo a color originales, 516 imágenes divididas en conjuntos de entrenamiento (413 imágenes) y conjunto de prueba (103 imágenes). Etiquetas del grado de enfermedad de la retinopatía diabética y el edema macular diabético (dividido en conjuntos de entrenamiento y prueba)
- C. Localización: consta de imágenes de fondo de ojo a color originales 516 imágenes divididas en conjuntos de entrenamiento (413 imágenes) y conjunto de prueba (103 imágenes). Etiquetas para la ubicación del centro del disco óptico (dividido en conjuntos de entrenamiento y prueba). Etiquetas para la ubicación del centro de Fovea (dividido en conjuntos de entrenamiento y prueba)

Se utilizó el inciso B para realizar dos experimentos:

1. La primer prueba se realizó para la detección de retinopatía en cualquiera de sus grados. Se dividió el conjunto de datos con imágenes de fondo de ojo con algún grado de retinopatía (348) e imágenes de fondo ocular sano (148).

2. En la segunda se incluyeron imágenes de fondo ocular con grados de retinopatía (grado 1(25), grado 2(168), grado 3(93) y grado 4(62)) e imágenes de fondo ocular de personas sanas (168).

4.2. Pre procesamiento

El preprocesamiento mejora la calidad y consistencia de las imágenes, lo que resulta en un mejor rendimiento de los algoritmos de visión por computadora. Al limpiar, normalizar y ajustar las imágenes antes de su análisis, el preprocesamiento permite una detección y reconocimiento de características más preciso, robusto y eficiente. Este paso es esencial para garantizar que los sistemas de visión artificial sean capaces de funcionar de manera óptima en una amplia variedad de condiciones y aplicaciones.

Aunque este paso es muy importante en cualquier sistema de visión, en nuestro caso no se seleccionó personalmente. Pues la intención de esta tesis es hacer un análisis comparativo de las técnicas de selección de características. Este paso fue seleccionado de forma similar al desarrollado en [24].

4.3. Segmentación

La segmentación de imágenes tiene una influencia crítica en los sistemas de visión por computadora, mejorando la precisión, eficiencia y relevancia del análisis. Al aislar los objetos de interés y reducir la complejidad de los datos, la segmentación facilita una serie de aplicaciones que van desde el reconocimiento de objetos hasta el control de calidad y la interpretación médica. Su correcta implementación es esencial para el éxito y la fiabilidad de cualquier sistema de visión artificial.

Aunque este paso es muy importante en cualquier sistema de visión, en nuestro caso, tampoco se seleccionó personalmente. Pues la intención de esta tesis es hacer un análisis comparativo de las técnicas de selección de características. Este paso fue seleccionado de forma similar al desarrollado en [24].

4.4. Extracción de características

La extracción de características es una etapa fundamental en los sistemas de visión por computadora que influye directamente en la precisión, eficiencia, y robustez del análisis de imágenes. Una adecuada extracción de características permite a los sistemas de visión abordar una amplia variedad de aplicaciones, desde la clasificación y el reconocimiento hasta la detección y el seguimiento de objetos, mejorando significativamente su desempeño y fiabilidad. Las características locales son extraídas a partir de una cierta región segmentada de la imagen.

En los experimentos realizados se trabajó con conjuntos de datos cuyas características extraídas fueron las siguientes:

- Momentos de Hu con intensidad para cada canal en RGB y HSV.
- Características HoG piramidales con intensidad.
- Características de Gabor.
- Media de intensidad para cada canal.
- Desviación estándar para cada canal.
- Contraste para cada canal.
- Gradiente en el borde para cada canal.
- Patrones binarios locales para cada canal.
- Intensidad de curtosis para cada canal.
- Descriptores texturales de Haralick.

En total se extrajeron 1992 características texturales y cromáticas.

4.4.1. Normalización de datos

En su forma más básica, la normalización de clasificaciones implica ajustar los valores medidos en diferentes escalas a una escala común, facilitando así su comparación directa y precisa. Este ajuste es especialmente útil cuando se necesita promediar valores provenientes de diferentes fuentes o métodos de medición.

En situaciones más complejas, la normalización puede referirse a procesos más sofisticados, cuyo objetivo es alinear las distribuciones de probabilidad de los valores ajustados. Esto implica realizar transformaciones que permitan comparar datos de diferentes conjuntos de manera coherente, eliminando los efectos de ciertas influencias generales que podrían sesgar los resultados. Al normalizar, se crean versiones modificadas de estadísticas, diseñadas para que estos valores normalizados puedan ser comparados entre sí de forma efectiva y justa, independientemente del conjunto de datos del que provengan.

Durante los experimentos realizados, se normalizó cada conjunto de datos dentro de un rango específico de valores para asegurar que los atributos sean comparables en algún sentido relevante. Debido a que los parámetros calculados pueden variar significativamente en sus rangos, es esencial realizar una transformación de datos adecuada. En este contexto, se implementó la normalización estándar. Si se conocen la media de la población y la desviación estándar, la normalización estándar de un vector x se calcula de la siguiente manera:

$$z = \frac{x - \mu}{\sigma} \quad (4.1)$$

Donde:

- μ : Es la media de la población.
- σ : Es la desviación estándar de la población.

La normalización permite comparar atributos y características de datos que originalmente están en diferentes escalas o unidades. Esto es fundamental en el reconocimiento de patrones, donde se deben identificar y comparar características relevantes de los datos. Al normalizar los datos, se eliminan los efectos de las diferencias de escala que podrían

introducir sesgos en los resultados. Esto garantiza que los análisis y las comparaciones se realicen de manera equitativa y objetiva.

En el análisis multivariable, es crucial que todas las variables tengan la misma escala para que ninguna domine sobre las otras. La normalización asegura que cada variable contribuya equitativamente al análisis, permitiendo una interpretación más precisa de las relaciones entre variables. Además, muchos algoritmos de machine learning, como los utilizados en el reconocimiento de patrones, se benefician de datos normalizados. La normalización puede mejorar la convergencia y la precisión de estos algoritmos, facilitando su entrenamiento y optimizando su desempeño.

En resumen, la normalización es una técnica fundamental en el reconocimiento de patrones y en el análisis de datos en general. Su aplicación garantiza que los datos sean comparables, se eliminen los sesgos, y se optimice el rendimiento de los algoritmos analíticos. Esto permite obtener resultados más precisos y fiables, facilitando la interpretación y la toma de decisiones basada en datos.

4.5. Clasificación e identificación

Este paso es crucial en el proceso de identificación y categorización de los objetos presentes en las imágenes. La eficiencia y la precisión del sistema dependerán en gran medida del clasificador utilizado, ya que este determina cómo se interpretan y reconocen las características de los objetos. En los experimentos realizados se utilizaron varios clasificadores, permitiendo así un análisis comparativo de su desempeño en términos de precisión, tiempo de procesamiento y capacidad de generalización.

Los modelos de clasificación utilizados en esta tesis fueron: redes neuronales, máquinas de soporte vectorial (SVM), árboles de decisión y Naive Bayes. Cada uno de estos clasificadores tiene características y metodologías distintas, lo que permite observar cómo diferentes enfoques pueden influir en la eficacia del sistema de reconocimiento de objetos. Las redes neuronales, con su capacidad de aprender representaciones complejas, son conocidas por su alto rendimiento en tareas de reconocimiento visual. Las máquinas de soporte vectorial, por su parte, son efectivas para clasificaciones lineales y no lineales mediante

el uso de distintos núcleos. Los árboles de decisión proporcionan una estructura de toma de decisiones fácil de interpretar, y Naive Bayes, basado en la probabilidad, es eficiente y robusto, especialmente con datos categóricos.

Con el objetivo de validar los resultados obtenidos y asegurar la fiabilidad del modelo, se utilizó la técnica de validación cruzada *k-fold*, con $k = 10$. Esta técnica es fundamental en el análisis estadístico y en la evaluación de modelos de aprendizaje automático, ya que garantiza que los resultados no sean producto de una partición específica entre los datos de entrenamiento y los datos de prueba.

La validación cruzada o cross-validation ([Hagan, 1996]) es una técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes particiones. Se utilizan en entornos donde el objetivo principal es la predicción y se quiere estimar cuán preciso es un modelo que se llevará a cabo en la práctica. Es una técnica muy utilizada en proyectos de inteligencia artificial para validar modelos generados.

La validación cruzada permite que cada subconjunto sea utilizado exactamente una vez como conjunto de prueba. Este enfoque asegura que todos los datos sean utilizados tanto para entrenamiento como para validación, proporcionando una evaluación robusta y menos sesgada del modelo.

Finalmente, se obtiene la media aritmética de los resultados de cada iteración para obtener un único resultado. Esta media aritmética refleja la capacidad del modelo para generalizar a datos no vistos, proporcionando una medida precisa y confiable de su rendimiento. La validación cruzada es particularmente útil en conjuntos de datos limitados, ya que maximiza el uso de los datos disponibles y minimiza el riesgo de sobreajuste.

4.6. Validación y evaluación

En esta sección se realiza un análisis exhaustivo de los resultados obtenidos con las diferentes técnicas de selección de características aplicadas en los experimentos. La evaluación de los modelos y la comparación de su desempeño se basan en diversas métricas de

rendimiento que proporcionan una visión integral de su eficacia y eficiencia. Las métricas de comparación utilizadas son AUC, F-measure y precisión.

La área bajo la curva (AUC) de la curva ROC (Receiver Operating Characteristic) es una métrica fundamental para evaluar el rendimiento de los clasificadores binarios. La AUC proporciona una medida agregada del rendimiento del clasificador a través de todos los umbrales de clasificación posibles, reflejando la capacidad del modelo para distinguir entre las clases positivas y negativas. Un valor de AUC cercano a 1 indica un excelente desempeño del clasificador, mientras que un valor de AUC de 0.5 sugiere que el modelo no es mejor que un azar.

La F-measure o F1 score es una métrica que combina la precisión y la recuperación en un solo valor, proporcionando una medida equilibrada del rendimiento del modelo, especialmente útil cuando se tiene un conjunto de datos desequilibrado. La F-measure es la media armónica de la precisión (proporción de verdaderos positivos entre todos los positivos predichos) y la recuperación (proporción de verdaderos positivos entre todos los positivos reales). Una alta F-measure indica que el modelo tiene tanto una alta precisión como una alta recuperación, lo que es deseable en muchas aplicaciones prácticas.

La precisión es una métrica clave para evaluar modelos de clasificación en sistemas de visión, especialmente en situaciones donde los costos de los falsos positivos son significativos. Al analizar la precisión junto con otras métricas, como la AUC y el F1 score, se puede obtener una visión más completa del rendimiento del modelo.

El análisis de estas métricas proporciona una visión integral del rendimiento de los modelos de selección de características. Al comparar AUC, F-measure, sensibilidad y especificidad, se puede determinar qué técnica ofrece el mejor equilibrio entre los diferentes aspectos del rendimiento del modelo. Además, este enfoque permite identificar las fortalezas y debilidades de cada técnica, facilitando la selección de la estrategia más adecuada para el problema en cuestión.

La validación y evaluación utilizando estas métricas no solo garantizan una evaluación precisa y fiable de los modelos, sino que también proporcionan información valiosa para la mejora continua y la optimización de las técnicas de selección de características. Este análisis riguroso es esencial para asegurar que los sistemas desarrollados sean robustos,

eficientes y capaces de generalizar bien a nuevos datos.

Capítulo 5

Resultados experimentales

En este Capítulo se describen los resultados obtenidos. Esta tesis se utilizaron algoritmos genéticos para la selección de características. Esto permite reducir el tiempo de entrenamiento y mejorar la precisión de clasificación. En su totalidad, las características extraídas son utilizadas para entrenar el clasificador y comparado el desempeño con el método de extracción de características usando el AG. En todas las pruebas realizadas se utilizaron 5 clasificadores.

5.1. Conjunto A

El primer conjunto de imágenes fue obtenido de [2] este ha sido utilizado por los mismos autores en varios artículos [1]. El conjunto de datos puede ser encontrado en <https://www5.cs.fau.de/research/data/fundus-images/>.

El conjunto de imágenes está compuesto por 45 imágenes de tres clases con una resolución de 3504 x 2336 pixeles y almacenados en formato TIF:

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 utilizado a) Retinopatía diabética b) Glaucoma c) Saludable

5.1.1. Desempeño utilizando todas las características (Conjunto A)

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).

Cuadro 5.1: Resultados utilizando todas las características

	Precisión	AUC-ROC	F-Measure	Clase
Bayes	0.81	0.93	0.77	1
	0.65	0.85	0.71	2
	0.90	0.92	0.88	3
SMO	0.95	0.97	0.93	1
	0.73	0.87	0.75	2
	0.75	0.85	0.82	3
NN	0.83	0.88	0.82	1
	0.84	0.88	0.83	2
	0.90	0.82	0.97	3
DT	0.81	0.91	0.85	1
	0.78	0.82	0.71	2
	0.88	0.92	0.91	3

La Tabla 5.1 muestra los resultados de evaluación de varios algoritmos de clasificación utilizando todas las características disponibles. Los algoritmos evaluados incluyen Naive Bayes (Bayes), Support Vector Machines (SMO), Redes Neuronales (NN) y Árboles de Decisión (DT). Los resultados se presentan para tres clases diferentes, evaluados mediante tres métricas: Precisión, Área Bajo la Curva de la Característica Operativa del Receptor (AUC-ROC) y F-Measure.

La Tabla está organizada en cuatro columnas que representan diferentes métricas de evaluación y una fila para cada algoritmo de clasificación en diferentes clases.

Bayes: Ofrece un buen rendimiento general, con la mayor precisión en la Clase 3 y

el mejor AUC-ROC en la Clase 1. Sin embargo, su desempeño es menor en la Clase 2. SMO: Muestra el mejor desempeño en la Clase 1 con alta precisión y AUC-ROC, aunque su rendimiento disminuye en las Clases 2 y 3. NN (Redes Neuronales): Proporciona un equilibrio en el rendimiento para las Clases 1 y 2, con un desempeño excepcional en la Clase 3, destacando en la F-Measure. DT (Árboles de Decisión): Exhibe un desempeño sólido en la Clase 3 con alta precisión y F-Measure, aunque tiene una precisión relativamente baja en la Clase 2.

La Tabla 5.1 compara el rendimiento de varios algoritmos de clasificación utilizando todas las características disponibles. Los resultados indican que cada algoritmo tiene fortalezas y debilidades específicas en función de la clase de interés. La elección del mejor modelo puede depender del objetivo específico de clasificación y del balance entre precisión, AUC-ROC y F-Measure para las distintas clases.

5.1.2. Desempeño con selección de datos (Conjunto A)

Cuadro 5.2: Resultados utilizando características reducidas por tres algoritmos

	Algoritmo genético			Selección Hacia Adelante			Eliminación Hacia Atras			Clase
	Precisión	AUC-ROC	F-Measure	Precisión	AUC-ROC	F-Measure	Precisión	AUC-ROC	F-Measure	
Bayes	0.88	0.93	0.83	0.78	0.91	0.75	0.79	0.91	0.75	1
	0.81	0.86	0.80	0.62	0.84	0.70	0.67	0.87	0.73	2
	0.85	0.91	0.87	0.89	0.91	0.86	0.86	0.89	0.84	3
SMO	0.91	0.98	0.95	0.92	0.95	0.92	0.93	0.95	0.91	1
	0.93	0.95	0.91	0.71	0.88	0.75	0.72	0.87	0.74	2
	0.91	0.95	0.93	0.72	0.84	0.80	0.71	0.83	0.80	3
NN	0.87	0.91	0.89	0.80	0.86	0.79	0.78	0.84	0.77	1
	0.87	0.92	0.88	0.84	0.87	0.82	0.80	0.83	0.79	2
	0.91	0.95	0.93	0.88	0.79	0.92	0.88	0.80	0.91	3
DT	0.85	0.96	0.89	0.80	0.90	0.85	0.78	0.88	0.82	1
	0.83	0.91	0.83	0.77	0.82	0.70	0.77	0.81	0.69	2
	0.92	0.95	0.93	0.88	0.91	0.90	0.87	0.90	0.90	3

La Tabla 5.2 presentada muestra los resultados de la evaluación de modelos utilizando diferentes técnicas de selección de características en combinación con tres algoritmos de clasificación diferentes: Naive Bayes, Support Vector Machines (SMO), Redes Neuronales

Artificiales (NN) y Árboles de Decisión (DT). La tabla está organizada para comparar el desempeño de los modelos en términos de tres métricas clave: Precisión, Área Bajo la Curva de la Característica Operativa del Receptor (AUC-ROC) y F-Measure.

La Tabla 5.2 está dividida en tres secciones principales: "Algoritmo genético", "Selección Hacia Adelante", y "Eliminación Hacia Atrás". Cada sección compara los resultados de los diferentes métodos de selección de características utilizando los algoritmos de clasificación mencionados.

Las filas están etiquetadas con diferentes algoritmos y números de clase. Cada fila muestra los resultados de un algoritmo específico usando diferentes métodos de selección de características para tres clases (1, 2 y 3).

Algoritmo Genético muestra resultados variados con la mejor precisión y AUC-ROC para la clase 1 y una F-Measure más alta en la clase 3. Selección Hacia Adelante proporciona un rendimiento equilibrado en la clase 3, con una precisión relativamente alta y una buena F-Measure, aunque la precisión para la clase 2 es más baja. Eliminación Hacia Atrás también muestra variabilidad en los resultados con una precisión destacable en la clase 3 y AUC-ROC superior en la clase 1.

La Tabla 5.2 ofrece una visión clara del impacto de los diferentes métodos de selección de características en el rendimiento de diversos algoritmos de clasificación. Los resultados sugieren que la elección del método de selección y el algoritmo de clasificación pueden influir significativamente en la precisión y la capacidad de los modelos para distinguir entre diferentes clases.

Para comparar los resultados obtenidos en las dos Tablas (5.1 y 5.2), debemos observar y contrastar el rendimiento de los algoritmos de clasificación en términos de Precisión, AUC-ROC y F-Measure, tanto al utilizar todas las características como al usar solo las características reducidas por el Algoritmo Genético (AG), Selección Hacia Adelante y Eliminación Hacia Atrás. Comparación de Resultados

El uso de características reducidas por el Algoritmo Genético tiende a mejorar el rendimiento general de los algoritmos de clasificación en comparación con el uso de todas las características, especialmente en términos de precisión y F-Measure. La Selección Hacia Adelante y la Eliminación Hacia Atrás también ofrecen mejoras en comparación con todas

las características, pero no tan pronunciadas como el Algoritmo Genético. Los resultados indican que la reducción de características, especialmente mediante el Algoritmo Genético, puede optimizar el rendimiento de los modelos de clasificación al eliminar características irrelevantes o redundantes.

5.2. Conjunto B

El segundo conjunto de datos fue obtenido de [20]. Este conjunto de datos se conoce como Indian diabetic retinopathy image dataset (IDRiD). El conjunto de datos fue elaborado por clinical examinations at the Nanded (M.S.), eye clinic in India. El conjunto de datos está disponible al público. El conjunto de datos es una colección de 516 imágenes con una resolución de 4288×2848 pixeles y almacenado en formato JPG.

El conjunto de imágenes está dividido en tres partes:

1. Segmentación: Consiste en imágenes de fondo de ojo a color (81 imágenes divididas en conjuntos de entrenamiento y prueba). Imágenes de lesiones (micro aneurismas, hemorragias, exudados duros y exudados blandos divididos en conjuntos de entrenamiento y prueba) y disco óptico (dividido en conjunto de entrenamiento y prueba)
2. Clasificación de enfermedades: consiste en Imágenes de fondo de ojo a color originales, 516 imágenes divididas en conjuntos de entrenamiento (413 imágenes) y conjunto de prueba (103 imágenes). Etiquetas del grado de enfermedad de la retinopatía diabética y el edema macular diabético (dividido en conjuntos de entrenamiento y prueba)
3. Localización: consta de imágenes de fondo de ojo a color originales 516 imágenes divididas en conjuntos de entrenamiento (413 imágenes) y conjunto de prueba (103 imágenes). Etiquetas para la ubicación del centro del disco óptico (dividido en conjuntos de entrenamiento y prueba). Etiquetas para la ubicación del centro de Fóvea (dividido en conjuntos de entrenamiento y prueba)

Se utilizó el inciso B para realizar dos experimentos:

1. La primera prueba se realizó para la detección de retinopatía en cualquiera de sus grados. Se dividió el conjunto de datos con imágenes de fondo de ojo con algún grado de retinopatía (348) e imágenes de fondo ocular sano (148).
2. En la segunda se incluyeron imágenes de fondo ocular de la siguiente manera:
 - 168 imágenes con grado de retinopatía 0 (32.6 %)
 - 25 imágenes con grado de retinopatía 1 (4.8 %)
 - 168 imágenes con grado de retinopatía 2 (32.6 %)
 - 93 imágenes con grado de retinopatía 3 (18 %)
 - 62 imágenes con grado de retinopatía 4 (12 %)

El grado de retinopatía varia de 0 a 4. El grado 0 representa a un ojo sano y a mayor grado representa la gravedad de la enfermedad. El grado 4 representa la condición más severa de retinopatía diabética.




Figura 5.2: Conjunto de datos utilizado a) Grado de retinopatía 0 b) Grado de retinopatía 1 c) Grado de retinopatía 2 d) Grado de retinopatía 3 e) Grado de retinopatía 4

5.2.1. Desempeño utilizando todas las características (Conjunto B)

El segundo conjunto de datos fue obtenido de [20] y este puede ser obtenido en <https://iee-dataport.org/open-access/indian-diabetic-retinopathy-image-dataset-idrid>. El conjunto de datos contiene 516 imágenes con una resolución de 4288×2848 píxeles.

El conjunto de datos tiene imágenes con diferentes grados de retinopatía. Cada una de las clases o grados de retinopatía contiene un diferente número de imágenes, es decir el conjunto de datos no está balanceado. Este conjunto de datos es más grande y esto puede ayudar a obtener una mejor idea tanto del desempeño de los clasificadores como de los descriptores utilizados.

Esto debido a que en el conjunto de datos 1 los datos están completamente balanceados,

además el conjunto de datos es muy pequeño. En los experimentos realizados, se realizaron dos tipos de pruebas con este conjunto de datos. En la primera prueba, se dividió el conjunto original en solo dos clases (sano y retinopatía), mientras que en la segunda prueba se utilizaron todas las clases. La clase sana y cuatro grados de retinopatía.

5.2.2. Desempeño con selección de datos (Conjunto B)

Cuadro 5.3: Resultados de la detección en grados de retinopatía

	Clasificador	Métrica		
		Precisión	F-measure	ROC
Todas las Características	SVM	0.39	0.45	0.64
	DT	0.45	0.48	0.56
	Bayes	0.41	0.43	0.53
	NN	0.44	0.48	0.58
Algoritmo genético	SVM	0.43	0.48	0.71
	DT	0.47	0.51	0.58
	Bayes	0.43	0.45	0.62
	NN	0.47	0.52	0.65
Selección Hacia Adelante	SVM	0.36	0.42	0.56
	DT	0.44	0.46	0.55
	Bayes	0.38	0.41	0.52
	NN	0.45	0.49	0.59
Eliminación Hacia Atras	SVM	0.41	0.46	0.65
	DT	0.45	0.49	0.58
	Bayes	0.45	0.49	0.56
	NN	0.45	0.46	0.57

La Tabla 5.3 presenta los resultados de detección en grados de retinopatía utilizando diferentes clasificadores y métodos de selección de características.

Las columnas indican el tipo de clasificador utilizado para la detección y las métricas utilizadas que incluyen tres medidas de rendimiento: Precisión, F-Measure y ROC.

El clasificador basado en árboles de decisión muestra la mejor precisión al utilizar todas las características (0.45). Mientras que las redes neuronales con el Algoritmo Genético tiene la precisión más alta (0.47), seguido por DT con el Algoritmo Genético (0.47). SVM y Bayes no muestran mejoras significativas en precisión con respecto a la selección de características.

El mejor rendimiento en F-Measure se observa con las redes neuronales usando el Algoritmo Genético (0.52). La Selección Hacia Adelante y la Eliminación Hacia Atrás tienden a reducir el rendimiento en comparación con el uso de todas las características para algunos clasificadores.

La métrica ROC, que indica la capacidad de los clasificadores para distinguir entre clases, es más alta con el Algoritmo Genético en comparación con otras técnicas para la mayoría de los clasificadores, especialmente para SVM (0.71) y NN (0.65).

En resumen, el Algoritmo Genético generalmente ofrece una mejora en la métrica ROC y muestra un rendimiento competitivo en precisión y F-Measure. La Selección Hacia Adelante y la Eliminación Hacia Atrás no siempre mejoran las métricas en comparación con el uso de todas las características.

Capítulo 6

Conclusiones

En esta Tesis se han realizado exhaustivas pruebas utilizando diversos algoritmos de selección de características para la clasificación de retinopatía, incluyendo métodos como la selección hacia adelante, la eliminación hacia atrás y los algoritmos genéticos. Estos experimentos han implicado no solo la aplicación de estas técnicas de selección de características, sino también su combinación con diferentes métodos de clasificación para evaluar su eficacia en el contexto de la detección y diagnóstico de retinopatía.

A lo largo de los experimentos, se ha llevado a cabo una serie de pruebas para cada una de las técnicas de selección de características mencionadas, y se ha observado su impacto en la precisión, la medida F y el área bajo la curva ROC (AUC-ROC) de los modelos de clasificación. Los resultados obtenidos han sido analizados detalladamente en el Capítulo anterior, proporcionando una visión comprensiva del desempeño de cada técnica en diferentes configuraciones y conjuntos de datos.

De los resultados presentados y analizados, se puede argumentar que:

1. **Eficiencia de las Técnicas de Selección:** La selección de características tiene un impacto significativo en el rendimiento de los clasificadores. Algunas técnicas de selección, como los algoritmos genéticos, han mostrado mejoras notables en términos de AUC-ROC y F-Measure, mientras que otros métodos como la selección hacia adelante y la eliminación hacia atrás pueden no siempre ofrecer mejoras consistentes en todas las métricas.

2. **Comparación entre Algoritmos de Clasificación:** La combinación de diferentes técnicas de selección de características con diversos algoritmos de clasificación ha revelado que ciertos clasificadores, como las redes neuronales y los árboles de decisión, pueden beneficiarse más de técnicas específicas de selección de características. Esto sugiere que la selección de características puede ser especialmente crucial para optimizar el rendimiento de ciertos clasificadores.
3. **Impacto en la Precisión y la Medida F:** Los resultados de precisión y medida F varían significativamente según la técnica de selección de características utilizada y el clasificador aplicado. Algunas técnicas de selección mejoran la precisión general, mientras que otras afectan más a la medida F, indicando una posible compensación entre la precisión y la capacidad de capturar la información relevante.

En trabajos futuros, se debería considerar, la incorporación de nuevas técnicas de selección de características, así como la combinación de métodos existentes de manera innovadora, podría llevar a mejoras adicionales en el rendimiento de los modelos. Es recomendable investigar métodos híbridos o adaptativos que puedan optimizar la selección de características en función de las características específicas del conjunto de datos.

La evaluación de técnicas avanzadas de clasificación, como los métodos de aprendizaje profundo y los enfoques basados en redes neuronales convolucionales (CNN), podría ofrecer nuevas perspectivas y mejoras en la clasificación de retinopatía.

En conclusión, los resultados obtenidos proporcionan una base sólida para futuras investigaciones y mejoras en la clasificación de retinopatía, abriendo la puerta a nuevas oportunidades para optimizar los modelos de detección y diagnóstico en el campo de la visión artificial y el aprendizaje automático.

Bibliografía

- [1] A. Budai et al. “Robust Vessel Segmentation in Fundus Images”. En: *International Journal of Biomedical Imaging* 2013 (2013), págs. 1-11. DOI: 10.1155/2013/154860. URL: <https://www5.cs.fau.de/research/data/fundus-images/>.
- [2] Attila Budai. *Pattern Recognition Lab (CS5), the Department of Ophthalmology, Friedrich-Alexander University Erlangen-Nuremberg (Germany), and the Brno University of Technology, Faculty of Electrical Engineering and Communication, Department of Biomedical Engineering, brno (Czech Republic)*. 2009. URL: <https://www5.cs.fau.de/research/data/fundus-images/>.
- [3] Jair Cervantes, Xiaou Li y Wen Yu. “Splice site detection in DNA sequences using a fast classification algorithm”. En: *2009 IEEE International Conference on Systems, Man and Cybernetics*. IEEE, oct. de 2009. DOI: 10.1109/icsmc.2009.5346130.
- [4] Jair Cervantes et al. “A comprehensive survey on segmentation techniques for retinal vessel segmentation”. En: *Neurocomputing* 556 (nov. de 2023), pág. 126626. ISSN: 0925-2312. DOI: 10.1016/j.neucom.2023.126626.
- [5] Jair Cervantes et al. “A Fast SVM Training Algorithm Based on a Decision Tree Data Filter”. En: *Advances in Artificial Intelligence*. Springer Berlin Heidelberg, 2011, págs. 187-197. ISBN: 9783642253249. DOI: 10.1007/978-3-642-25324-9_16.
- [6] Peter Christen, David J. Hand y Nishadi Kirielle. “A Review of the F-Measure: Its History, Properties, Criticism, and Alternatives”. En: *ACM Computing Surveys* 56.3 (oct. de 2023), págs. 1-24. ISSN: 1557-7341. DOI: 10.1145/3606367.

-
- [7] Jacobo Gomez-Conde et al. “Quality of performance metrics, informal peer monitoring and goal commitment”. En: *Accounting amp; Finance* 62.3 (feb. de 2022), págs. 4041-4077. ISSN: 1467-629X. DOI: 10.1111/acfi.12915.
- [8] Martin T. Hagan, Howard B. Demuth y Mark Beale. *Neural network design*. PWS Publishing Co., 1997.
- [9] Laura Jalili et al. “Emotion Recognition from Facial Expressions Using a Genetic Algorithm to Feature Extraction”. En: *Intelligent Computing Theories and Application*. Springer International Publishing, 2021, págs. 59-71. DOI: 10.1007/978-3-030-84522-3_5.
- [10] Laura D. Jalili et al. “Improving the Performance of Leaves Identification by Features Selection with Genetic Algorithms”. En: *Communications in Computer and Information Science*. Springer International Publishing, 2016, págs. 103-114. DOI: 10.1007/978-3-319-50880-1_10.
- [11] Firuz Kamalov et al. “Forward feature selection: empirical analysis”. En: *Journal of Intelligent Systems and Internet of Things* 11.1 (2024), págs. 44-54. DOI: 10.54216/jisiot.110105.
- [12] Tuomas Korhonen et al. “How performance measurement can support achieving success in project-based operations”. En: *International Journal of Project Management* 41.1 (ene. de 2023), pág. 102429. ISSN: 0263-7863. DOI: 10.1016/j.ijproman.2022.11.002.
- [13] Michel J. Lebas. “Performance measurement and performance management”. En: *International Journal of Production Economics* 41.1-3 (oct. de 1995), págs. 23-35. ISSN: 0925-5273. DOI: 10.1016/0925-5273(95)00081-x.
- [14] Francisco Macedo et al. “Theoretical foundations of forward feature selection methods based on mutual information”. En: *Neurocomputing* 325 (ene. de 2019), págs. 67-89. ISSN: 0925-2312. DOI: 10.1016/j.neucom.2018.09.077.

- [15] A. Marcano-Cedeno et al. “Feature selection using Sequential Forward Selection and classification applying Artificial Metaplasticity Neural Network”. En: *IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society*. IEEE, nov. de 2010. DOI: 10.1109/iecon.2010.5675075.
- [16] F Maulidina et al. “Feature optimization using Backward Elimination and Support Vector Machines (SVM) algorithm for diabetes classification”. En: *Journal of Physics: Conference Series* 1821.1 (mar. de 2021), pág. 012006. ISSN: 1742-6596. DOI: 10.1088/1742-6596/1821/1/012006.
- [17] G. Nagarajan et al. “Hybrid Genetic Algorithm for Medical Image Feature Extraction and Selection”. En: *Procedia Computer Science* 85 (2016), págs. 455-462. DOI: 10.1016/j.procs.2016.05.192.
- [18] Arundhati Navada et al. “Overview of use of decision tree algorithms in machine learning”. En: *2011 IEEE Control and System Graduate Research Colloquium*. IEEE, jun. de 2011. DOI: 10.1109/icsgrc.2011.5991826.
- [19] Tatiana Cristina Figueira Polo y Hélio Amante Miot. “Aplicações da curva ROC em estudos clínicos e experimentais”. En: *Jornal Vascular Brasileiro* 19 (2020). ISSN: 1677-5449. DOI: 10.1590/1677-5449.200186.
- [20] Samiksha Pachade Prasanna Porwal. *Indian Diabetic Retinopathy Image Dataset (IDRiD)*. 2018. DOI: 10.21227/H25W98. URL: <https://ieee-dataport.org/open-access/indian-diabetic-retinopathy-image-dataset-idrid>.
- [21] R.A.Welikala et al. “Genetic algorithm based feature selection combined with dual classification for the automated detection of proliferative diabetic retinopathy”. En: *Computerized Medical Imaging and Graphics* 43 (jul. de 2015), págs. 64-77. DOI: 10.1016/j.compmedimag.2015.03.003.
- [22] David Souder et al. “Performance metrics in strategy research: A new metric and method for assessing dynamic value”. En: *Strategic Management Journal* 45.1 (sep. de 2023), págs. 144-167. ISSN: 1097-0266. DOI: 10.1002/smj.3550.

-
- [23] J.M. Sutter y J.H. Kalivas. “Comparison of Forward Selection, Backward Elimination, and Generalized Simulated Annealing for Variable Selection”. En: *Microchemical Journal* 47.1–2 (feb. de 1993), págs. 60-66. ISSN: 0026-265X. DOI: 10.1006/mchj.1993.1012.
- [24] Maria Fernanda Urdanez Carbajal. *Detección Automática de Glaucoma y Retinopatía Diabética Usando Características Cromáticas y Texturales*. 2020.
- [25] Vikramkumar, B Vijaykumar y Trilochan. *Bayes and Naive Bayes Classifier*. 2014. DOI: 10.48550/ARXIV.1404.0933.
- [26] Spruyt Vincent. *The curse of dimensionality in classification*. 2014.
- [27] César Aristóteles Yajure-Ramírez. “Enfoque multicriterio para la selección óptima de variables explicativas para modelos de pronóstico de la energía eléctrica de plantas solares fotovoltaicas”. En: *Revista Tecnológica - ESPO* 35.3 (dic. de 2023), págs. 83-98. ISSN: 0257-1749. DOI: 10.37815/rte.v35n3.1045.