

Tipo de artículo: Artículo de revisión

Análisis integral de algoritmos de clasificación en aprendizaje automático: perspectivas, comparaciones y aplicaciones

Comprehensive analysis of classification algorithms in machine learning: perspectives,
comparisons and applications

José Luis Romero Ibarra ^{1*}, <https://orcid.org/0000-0002-7527-4968>

¹ Instituto Superior Tecnológico ARGOS, Guayaquil, Ecuador.

*Autor para la correspondencia. j_romero@tecnologicoargos.edu.ec

RESUMEN

La evaluación de algoritmos de clasificación en aprendizaje automático es crucial para garantizar un desempeño óptimo en diversas aplicaciones. Esta revisión bibliográfica analizó métricas y estrategias para evaluar la efectividad de los modelos clasificadores. Se examinaron métricas básicas como precisión, sensibilidad y especificidad, que miden el desempeño en términos de predicciones correctas para clases positivas y negativas. También se abordó el valor F1, que combina precisión y sensibilidad para proporcionar un equilibrio entre ambas. Se exploraron métricas avanzadas, como el área bajo la curva ROC, que evalúa la capacidad del modelo para clasificar correctamente mediante diferentes umbrales de decisión. Además, se destacó la matriz de confusión, que ofrece una representación detallada de las predicciones correctas e incorrectas del modelo. La revisión también consideró criterios de inclusión y exclusión para seleccionar investigaciones relevantes sobre algoritmos de clasificación. Estos criterios garantizan la calidad y relevancia de los estudios, permitiendo una evaluación robusta y comprensiva de enfoques y técnicas en el campo. Esta revisión proporciona una visión detallada de las métricas de evaluación para algoritmos de



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

clasificación y resalta aspectos clave al buscar y analizar estudios relevantes. Este análisis es fundamental para comprender y aplicar de manera efectiva estos algoritmos en diversos contextos y aplicaciones prácticas.

Palabras clave: algoritmos de clasificación; aprendizaje automático; métricas de evaluación; rendimiento del modelo; validación de modelos.

ABSTRACT

Evaluating classification algorithms in machine learning is crucial to ensure optimal performance in various applications. This literature review analyzed metrics and strategies to evaluate the effectiveness of classifier models. Basic metrics such as accuracy, sensitivity, and specificity, which measure performance in terms of correct predictions for positive and negative classes, were examined. The F1 value, which combines accuracy and sensitivity to provide a balance between the two, was also addressed. Advanced metrics such as the area under the ROC curve, which assesses the model's ability to correctly classify using different decision thresholds, were explored. Additionally, the confusion matrix, which provides a detailed representation of the correct and incorrect predictions of the model, was highlighted. The review also considered inclusion and exclusion criteria to select relevant research on classification algorithms. These criteria ensure the quality and relevance of studies, allowing for a robust and comprehensive evaluation of approaches and techniques in the field. This review provides a detailed overview of evaluation metrics for classification algorithms and highlights key aspects when searching and analyzing relevant studies. This analysis is essential to effectively understand and apply these algorithms in various contexts and practical applications.

Keywords: Classification algorithms; machine learning; evaluation metrics; model performance; model validation.

Recibido: 03/12/2024

Aceptado: 15/01/2025

En línea: 31/01/2025



Introducción

En el aprendizaje automático, una rama de la inteligencia artificial, los algoritmos se utilizan para analizar datos e intentar extraer patrones potenciales en los datos para predecir nueva información (Hassan et al., 2020). Como nuevo método de análisis de datos y procesamiento, el aprendizaje automático se ha utilizado ampliamente en muchos campos debido a su alta precisión, personalización flexible y extensibilidad conveniente. Los datos relacionales no lineales complejos se pueden manejar fácilmente con el aprendizaje automático, lo que facilita el descubrimiento de los mecanismos subyacentes (Borodulin et al., 2024).

La excelente adaptabilidad del aprendizaje automático ha demostrado su potencial como herramienta en los campos de la ciencia e ingeniería ambiental en los últimos años. Por lo tanto, se pueden esperar resultados de evaluación más precisos a pesar de la complejidad de usar el aprendizaje automático para el análisis y la evaluación de problemas diversos (Xie et al., 2020).

La clasificación supervisada es una de las tareas realizada con más frecuencia por los sistemas inteligentes. Por lo tanto, se ha desarrollado una gran cantidad de técnicas basadas en la inteligencia artificial: técnicas basadas en la lógica, técnicas basadas en Perceptron; y estadísticas: redes bayesianas, técnicas basadas en instancias (Merjulah & Chandra, 2019). El objetivo del aprendizaje supervisado es construir un modelo conciso de la distribución de etiquetas de clase en términos de características predictoras. El clasificador resultante se usa para asignar etiquetas de clase a las instancias de prueba donde se conocen los valores de las características predictoras, pero se desconoce el valor de la etiqueta de clase. Este documento describe varios algoritmos de clasificación de en aprendizaje automático haciendo énfasis en sus perspectivas, comparaciones y aplicaciones.

El aprendizaje automático se ha vuelto cada vez más importante en la clasificación debido a su efectividad en el análisis de amplias cantidades de datos, de forma eficiente y óptima en el tiempo. Uno de los aspectos clave son los algoritmos de clasificación. Estos algoritmos abarcan desde métodos tradicionales como la regresión logística y el árbol de decisiones hasta enfoques más avanzados como las estructuras que contemplan redes neuronales y las Máquinas Vectoriales de Soporte (SVM) (Kumar et al., 2024). Cada algoritmo tiene sus propias características, ventajas y desventajas, y comprender su funcionamiento es fundamental para seleccionar el enfoque más adecuado para un problema dado.



En este contexto, la presente investigación tiene como objetivo realizar una Revisión Sistemática de la Literatura (RSL) sobre los algoritmos de clasificación en aprendizaje automático.

Métodos o Metodología Computacional

El creciente interés en los algoritmos de clasificación en el ámbito del aprendizaje automático ha motivado la realización de una Revisión Sistemática de la Literatura (RSL) reciente, con el objetivo de analizar su efectividad, comparativa y aplicaciones en diversos campos. La RSL se llevó a cabo siguiendo las directrices PRISMA. En este contexto, se definió como pregunta central de investigación: ¿Cuáles son las métricas y estrategias más efectivas para evaluar el desempeño de los algoritmos de clasificación en aprendizaje automático en diversas aplicaciones? A partir de esta pregunta principal, se formularon las siguientes preguntas de la investigación (RQ, *Research Questions*):

- RQ 1. ¿Cuáles son los algoritmos de clasificación, mas implementados en aprendizaje automático?
- RQ 2. ¿Cuál es el papel de métricas avanzadas en la evaluación de la efectividad de los algoritmos de clasificación?
- RQ 3. ¿Cuáles son las perspectivas y aplicaciones de los algoritmos de clasificación de aprendizaje automático en diversos contextos?

La RSL consideró trabajos indexados en bases de datos y bibliotecas digitales clave, entre las que se incluyen: *IEEE Xplore*, *ACM Digital Library*, *Scopus*, *Web of Science*, *Science Direct (Elsevier)*, *Springer Link* y *Google Scholar*. Se incluyó exclusivamente literatura revisada por pares, con el fin de asegurar la calidad y rigor de los resultados. La revisión de la literatura se realizó en el período de septiembre a diciembre de 2024, con un enfoque en artículos publicados entre 2019 y 2024. Las publicaciones relevantes fueron clasificadas utilizando tres niveles de especificidad, basados en las palabras clave de búsqueda:

1. El nivel 1 utilizó la sentencia ("*algoritmos de clasificación*" AND "*aprendizaje automático*") OR ("*machine learning algorithms*" AND "*classification*"). Este nivel se centra en las búsquedas más generales relacionadas con algoritmos de clasificación dentro del contexto del aprendizaje automático. Incluye tanto el término en español como en inglés, permitiendo capturar una variedad amplia de literatura sobre el tema.



2. El nivel 2 implementó la sentencia (*"supervised learning"* OR *"unsupervised learning"*) AND *"classification algorithms"*) OR (*"decision tree"* AND *"classification"*) OR (*"ensemble methods"* AND *"classification algorithms"*). En este nivel se incluyen enfoques más específicos dentro del aprendizaje automático, abarcando tanto técnicas de aprendizaje supervisado como no supervisado, así como metodologías concretas como árboles de decisión y métodos de ensamble. Esto permite una búsqueda focalizada en estrategias específicas de clasificación.
3. El nivel 3 utilizó una sentencia más compleja (*"online learning algorithms"* AND *"classification"*) OR (*"active learning"* AND *"classification"*) OR (*"semi-supervised learning"* AND *"classification algorithms"*) OR (*"classification algorithms"* AND *"text classification"*) OR (*"speech recognition"* AND *"classification algorithms"*). Este nivel se centra en las aplicaciones y técnicas específicas de clasificación, incluyendo aprendizaje en línea, aprendizaje activo y semi-supervisado, así como aplicaciones en clasificación de texto y reconocimiento de voz. Este enfoque permite profundizar en aspectos más particulares de los algoritmos de clasificación dentro del aprendizaje automático.

Estos niveles están diseñados para guiar el proceso de búsqueda, desde lo más general hasta lo más específico, facilitando la identificación de literatura relevante y de alta calidad en el área de estudio. Además, el proceso de filtrado se realizó conforme a los siguientes criterios predefinidos:

- Se incluyeron artículos empíricos que utilizaran diversos enfoques de estudio, incluidos métodos experimentales y análisis cuantitativos.
- Los documentos debían abordar aplicaciones prácticas de algoritmos de clasificación en contextos concretos.
- Se aceptaron solo artículos de revistas y conferencias revisados por pares que presentaran resultados significativos sobre la efectividad de los algoritmos.
- Se excluyó el uso de enfoques puramente teóricos que no presentaran aplicaciones prácticas de algoritmos de clasificación.
- Se excluyeron los artículos a los que no se podía acceder al texto completo.

La Figura 1 ilustra el proceso de recuperación e inclusión de estudios primarios en la RSL. Inicialmente, se recuperaron 897 estudios a partir de las búsquedas automáticas utilizando diversos motores de búsqueda. A partir de esta recopilación inicial, 523 estudios fueron filtrados de acuerdo con los criterios de inclusión,



resultando en la eliminación de 257 estudios por tener acceso cerrado, 89 por ser puramente teóricos, 104 que eran estudios de revisión y otros 73 que no cumplían con requisitos específicos. Posteriormente, se llevó a cabo un segundo filtro basado en el título y el resumen de los artículos, eliminando 307 estudios adicionales; dentro de estos, 58 eran publicaciones de más de 10 años, 289 presentaban resultados insuficientes y 183 no cumplían con otros criterios establecidos. Finalmente, solo 44 estudios se sometieron a un análisis más profundo mediante la lectura del texto completo, resultando en la inclusión de 23 estudios relevantes en la RSL. Este proceso riguroso asegura que los estudios incluidos sean de alta calidad y pertinentes para el objeto de investigación.

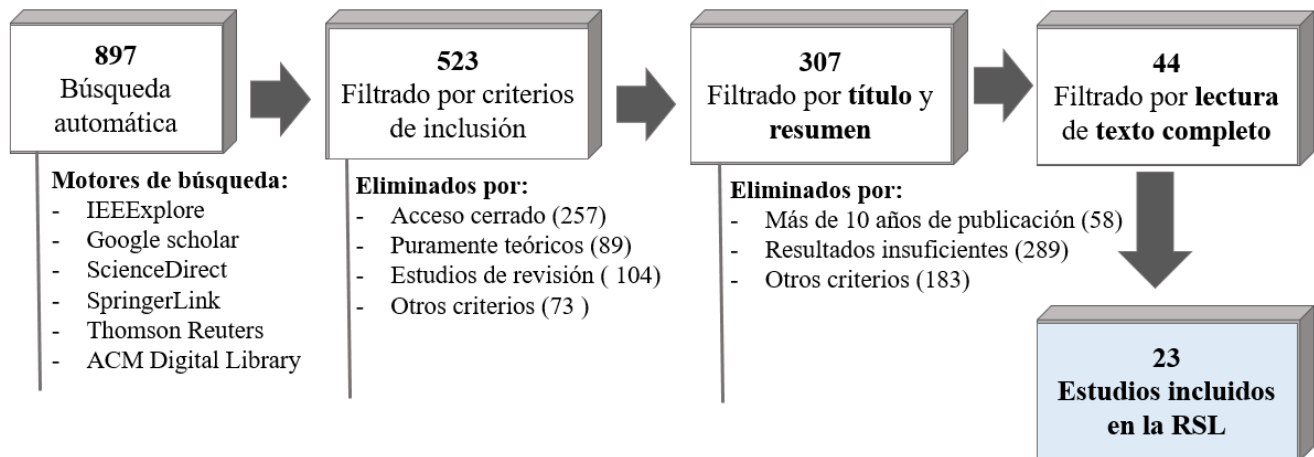


Figura 1. Recuperación e inclusión de estudios primarios en la RSL

Resultados y discusión

En la tabla 1 se resumen los 23 estudios recuperados que fueron incluidos en la presente RSL. Estos estudios fueron seleccionados tras el proceso de filtrado que garantizó su relevancia y calidad en el ámbito de los algoritmos de clasificación en aprendizaje automático. Cada uno de estos artículos aporta diferentes perspectivas y hallazgos acerca de las métricas de evaluación y la efectividad de los modelos clasificadores, permitiendo así una comprensión más profunda de la temática abordada. La tabla incluye información clave de cada estudio, facilitando una comparación detallada y el análisis correspondiente en el contexto de la presente investigación.



Tabla 1. Estudios primarios seleccionados en la RSL.

ID	Tema	Referencia
P1.	Squeeze-and-Excitation Networks	(Hu et al., 2019)
P2.	A feature aggregation convolutional neural network for remote sensing scene classification	(Lu et al., 2019)
P3.	An ensemble of convolutional neural networks for geospatial land classification.	(Minetto et al., 2019)
P4.	Self-Training with Noisy Student Improves ImageNet Classification.	(Xie et al., 2020)
P5.	Chaotic binary group search optimizer for feature selection	(Abualigah & Diabat, 2022)
P6.	Skip-connected covariance network for remote sensing scene classification	(He et al., 2019)
P7.	An intelligent prediction system for educational data mining based on ensemble and filtering approaches	(Ashraf et al., 2020)
P8.	Brain tumour classification using quantum support vector machine learning algorithm.	(Kumar et al., 2024)
P9.	Robust space–frequency joint representation for remote sensing image scene classification	(Fang et al., 2019)
P10.	Integration of Data Mining Classification Techniques and Ensemble Learning for Predicting the Export Potential of a Company	(Silva et al., 2019)
P11.	An optimization method for intrusion detection classification model based on Deep belief network	(Wei et al., 2019)
P12.	Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network.	(Abbas et al., 2021)
P13.	A lightweight and discriminative model for remote sensing scene classification with multidilation pooling module	(Zhang et al., 2019)
P14.	Chest X-ray image classification using faster R-CNN	(Rahmat et al., 2019)
P15.	Classification of different plant species using deep learning and machine learning algorithms	(Chouhan et al., 2024)
P16.	A new loss function for CNN classifier based on predefined evenly-distributed class centroids	(Zhu et al., 2019)
P17.	Comparison of three machine learning algorithms using google earth engine for land use land cover classification	(Zhao et al., 2024)
P18.	Scale-free convolutional neural network for remote sensing scene classification	(Xie et al., 2019)
P19.	Using machine learning algorithms to solve data classification problems using multi-attribute dataset.	(Borodulin et al., 2024)
P20.	An interactive teaching evaluation system for preschool education in universities based on machine learning algorithm	(Li, 2024)
P21.	Remote sensing scene classification by gated bidirectional network	(Sun et al., 2019)
P22.	Classification of myocardial ischemia in delayed contrast enhancement using machine learning.	(Merjulah & Chandra, 2019)
P23.	Developing intelligent medical image modality classification system using Deep transfer learning and LDA	(Hassan et al., 2020)

Los algoritmos de clasificación poseen una capacidad fundamental. Se anticipa la clase de datos objetivo al analizar la preparación de conjuntos de datos. Se utiliza el conjunto de datos de preparación para mejorar las condiciones límite que pueden emplearse para determinar cada clase objetivo. Una vez resueltas esas



condiciones límite, la siguiente tarea es predecir la clase de datos objetivo. Todo este proceso se conoce como técnica de clasificación (Fang et al., 2019).

Existen diferentes tipos de algoritmos que se utilizan en el proceso de clasificación. La distinción más importante entre regresión y clasificación radica en que la regresión predice cantidades continuas, mientras que la clasificación predice etiquetas de clase discretas. Ambos tipos de algoritmos de aprendizaje automático presentan ciertas similitudes y diferencias.

La clasificación es un pilar fundamental en el aprendizaje automático y abarca una variedad de enfoques, tanto supervisados como no supervisados, cada uno con sus propias características y aplicaciones. Dentro de este contexto, se pueden distinguir varios tipos de algoritmos, incluyendo aquellos basados en reglas y árboles de decisión (Fang et al., 2019).

Enfoques supervisados y no supervisados

Para el aprendizaje de tipo supervisado, el modelo se procedió a entrenar utilizando datos etiquetados, es decir, datos con las respuestas deseadas asociadas o clases a predecir. El propósito es desarrollar una función que vincule las características de entrada (atributos) con los resultados esperados. Durante la fase de entrenamiento, el modelo ajusta sus parámetros para reducir al mínimo la diferencia entre las predicciones y las respuestas reales. Después de haber sido entrenado, el modelo es capaz de hacer predicciones precisas sobre nuevos datos que no han sido etiquetados. Los algoritmos de clasificación y regresión son ejemplos comunes de enfoques supervisados, utilizados para predecir clases discretas o valores continuos, respectivamente (Wei et al., 2019).

En contraste, el aprendizaje no supervisado se aplica cuando los datos carecen de etiquetas y su objetivo principal es identificar patrones y estructuras subyacentes en los datos ocultos o características subyacentes en los datos (Borodulin et al., 2024). En este caso, el modelo busca agrupar los datos en clusters o segmentos de manera que los puntos de datos dentro de cada grupo sean similares entre sí, mientras que son diferentes de los puntos en otros grupos. Los algoritmos de clustering, como k-means y DBSCAN, son ejemplos de enfoques no supervisados, utilizados para explorar y segmentar conjuntos de datos sin la necesidad de etiquetas de clase previas (Rahmat et al., 2019).

El aprendizaje supervisado se dedica a entender la relación entre las características de entrada y las etiquetas de salida conocidas, mientras que el aprendizaje no supervisado se orienta hacia la identificación de



patrones y estructuras en los datos sin la ayuda de etiquetas predefinidas. Ambos enfoques tienen aplicaciones distintas y complementarias en el análisis de datos y el aprendizaje automático. La elección entre uno u otro depende del tipo de problema a resolver y de la disponibilidad de datos etiquetados.

Algoritmos basados en reglas

Los algoritmos basados en reglas son un tipo de técnica de aprendizaje automático que genera reglas explícitas para la clasificación o predicción de datos. Estos algoritmos se centran en identificar patrones y relaciones entre las características de los datos y las clases de interés, representándolos en forma de reglas *if-then*, donde se especifican condiciones sobre las características de entrada que deben cumplirse para predecir una clase específica (Ashraf et al., 2020).

Uno de los algoritmos basados en reglas más conocidos es el algoritmo de los k vecinos más cercanos (KNN), el cual clasifica las instancias de datos según las clases de los k vecinos más cercanos en el espacio de características. Otros ejemplos incluyen los clasificadores basados en reglas de asociación, como el algoritmo Apriori, que identifica patrones frecuentes en conjuntos de datos transaccionales para realizar predicciones (Lu et al., 2019).

Una de las principales ventajas de los algoritmos basados en reglas es su interpretabilidad, ya que las reglas generadas por estos algoritmos son fácilmente comprensibles para los humanos. Esto los hace especialmente útiles en aplicaciones donde la aplicabilidad del modelo es importante, como en el campo médico o legal.

Sin embargo, los algoritmos basados en reglas también tienen algunas limitaciones. Por ejemplo, pueden ser sensibles al ruido y a las inconsistencias en los datos, lo que puede influir negativamente en la calidad de las reglas generadas. Además, pueden tener dificultades para manejar conjuntos de datos con características numéricas continuas o de alta dimensionalidad (Rahmat et al., 2019).

Para superar algunas de estas limitaciones, se han sugerido diversas soluciones, por ejemplo, varias extensiones y mejoras de los algoritmos basados en reglas. Por ejemplo, se han desarrollado métodos para la selección automática de características y la poda de reglas para mejorar la calidad y la generalización de los modelos generados. Además, se han propuesto enfoques híbridos que combinan algoritmos basados en reglas con otros métodos de machine learning, como los árboles de decisión o las redes neuronales, para aprovechar las ventajas de ambos métodos (Li, 2024).

Algoritmos basados en árboles de decisión



Los algoritmos basados en árboles de decisión son una categoría popular de técnicas de aprendizaje automático empleadas tanto para la clasificación como para la regresión. Estos algoritmos se basan en la creación de estructuras de árbol que representan decisiones tomadas para clasificar o predecir instancias de datos. El proceso de construcción de un árbol de decisión consiste en dividir repetidamente el conjunto de datos en subconjuntos más pequeños basados en características específicas, con el objetivo de maximizar la pureza de las clases en cada subconjunto. Esto se logra mediante la selección de la característica y el umbral de división que mejor separan las clases en los subconjuntos resultantes. Los árboles de decisión pueden ser construidos utilizando diferentes algoritmos, como el algoritmo ID3, C4.5, CART y el algoritmo de árbol de decisión aleatorio (Zhao et al., 2024).

Una de las principales ventajas de los árboles de decisión es su habilidad para manejar tanto datos categóricos como numéricos, además de su capacidad para modelar relaciones no lineales entre variables de entrada y salida. Además, los árboles de decisión son altamente interpretables, lo que significa que los resultados del modelo pueden ser fácilmente comprendidos y explicados por los humanos (Ashraf et al., 2020).

Sin embargo, los árboles de decisión también presentan algunas limitaciones. Por ejemplo, pueden ser susceptibles al sobreajuste, especialmente cuando se construyen árboles muy profundos con conjuntos de datos pequeños. Además, los árboles de decisión tienden a ser menos precisos que otros métodos de aprendizaje automático en conjuntos de datos con características complejas y altamente correlacionadas (Borodulin et al., 2024).

Para superar algunas de estas limitaciones, se han propuesto diversas soluciones, como varias extensiones y mejoras de los árboles de decisión. Por ejemplo, los métodos de *ensemble*, como el *bagging* y el *boosting*, que combinan múltiples árboles de decisión para mejorar la precisión y la robustez del modelo. Además, se han desarrollado técnicas como la poda de árboles y la selección de características para reducir el sobreajuste y mejorar el rendimiento general del modelo (Ashraf et al., 2020).

Comparación de algoritmos de clasificación

La comparación de algoritmos de clasificación es esencial para entender sus fortalezas y debilidades en diferentes contextos y aplicaciones. Esto implica el análisis de métricas de evaluación, ventajas y



desventajas de los diferentes enfoques, así como la revisión de casos de estudio y resultados comparativos (Zhao et al., 2024).

Métricas de evaluación de algoritmos

Las métricas de evaluación, como la precisión, la sensibilidad, la especificidad y el área bajo la curva ROC (AUC-ROC), se emplean para medir el rendimiento de los algoritmos de clasificación. Estas métricas ofrecen una forma objetiva de comparar el desempeño de diferentes modelos y facilitan la selección del enfoque más adecuado para un problema específico (Xie et al., 2019).

Una de las métricas más comunes para evaluar algoritmos de clasificación es la precisión. Esta métrica mide la proporción de predicciones correctas realizadas por el modelo sobre el total de predicciones efectuadas. Aunque la precisión es importante, puede no ser suficiente para evaluar el rendimiento del modelo en todos los casos, especialmente cuando hay un desbalance de clases en el conjunto de datos (Xie et al., 2020).

Otra métrica relevante es la sensibilidad (*recall*), que mide la proporción de instancias positivas correctamente identificadas por el modelo. La sensibilidad es especialmente relevante en situaciones donde la detección de instancias positivas es crítica, como en el diagnóstico médico o la detección de fraudes.

La especificidad es una métrica complementaria a la sensibilidad, ya que mide la proporción de instancias negativas que el modelo identifica correctamente. La especificidad es importante en situaciones donde la identificación de instancias negativas es crucial, como en pruebas de seguridad y detección de intrusiones (Minetto et al., 2019).

Otra métrica ampliamente utilizada es el valor F1, el cual combina la precisión y la sensibilidad en una sola medida. El valor F1 es especialmente útil cuando se busca un equilibrio entre la precisión y la sensibilidad del modelo (Hassan et al., 2020).

Es importante considerar que la selección de las métricas de evaluación adecuadas depende del contexto específico del problema y de las necesidades del usuario. Al seleccionar métricas de evaluación, es fundamental considerar las características específicas del conjunto de datos, como el desbalance de clases, y las implicaciones prácticas de los resultados obtenidos por el modelo

Ventajas y desventajas de los diferentes enfoques

Cada enfoque de clasificación tiene sus propias ventajas y desventajas. Por ejemplo, los algoritmos basados en reglas son fácilmente interpretables, pero pueden no ser adecuados para conjuntos de datos con



características complejas. Por otro lado, los árboles de decisión pueden manejar datos heterogéneos, pero tienden a ser propensos al sobreajuste (Fang et al., 2019):

- Casos de estudio y resultados comparativos: El análisis de casos de estudio y resultados comparativos proporciona una visión práctica del desempeño de diferentes algoritmos de clasificación en escenarios del mundo real. Estos casos de estudio pueden abarcar una amplia gama de aplicaciones, como la clasificación de texto, el reconocimiento de voz y la detección de fraudes, y ayudan a ilustrar las fortalezas y limitaciones de cada enfoque.
- Aplicaciones de los algoritmos de clasificación en el aprendizaje automático: Los algoritmos de clasificación tienen una amplia gama de aplicaciones en el aprendizaje automático, que incluyen desde el análisis de texto y el procesamiento del lenguaje natural hasta la detección de fraudes y la seguridad informática.
- Clasificación de texto y análisis de sentimiento: En el ámbito del análisis de texto, los algoritmos de clasificación son utilizados para tareas como la clasificación de documentos, la detección de spam y el análisis de sentimientos en redes sociales. Estos algoritmos pueden identificar automáticamente el tono y la polaridad de un texto, lo que permite entender mejor las opiniones y emociones de los usuarios.
- Reconocimiento de voz y procesamiento del lenguaje natural: En el reconocimiento de voz y el procesamiento del lenguaje natural, los algoritmos de clasificación se utilizan para convertir señales de audio en texto y llevar a cabo tareas como la traducción automática, la generación de resúmenes y la respuesta automática a preguntas. Estos algoritmos permiten a las máquinas comprender y generar lenguaje humano de manera eficiente.
- Detección de fraudes y seguridad informática: En el ámbito de la seguridad informática, los algoritmos de clasificación se utilizan para identificar actividades fraudulentas y maliciosas, como transacciones fraudulentas, intrusiones en redes y ataques de phishing. Estos algoritmos pueden identificar patrones sospechosos en grandes volúmenes de datos y tomar medidas proactivas para mitigar riesgos de seguridad.

Factores a considerar en la selección de algoritmos de clasificación



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional** (CC BY 4.0)

Seleccionar el algoritmo de clasificación adecuado para un problema específico implica considerar una variedad de factores clave, que van desde el tamaño y la calidad del conjunto de datos, hasta el tiempo de entrenamiento y predicción, así como la interpretabilidad de los resultados obtenidos (Xie et al., 2019):

- **Tamaño y calidad del conjunto de datos:** El tamaño y la calidad del conjunto de datos tienen un impacto significativo en la selección del algoritmo de clasificación más apropiado. Algoritmos como las máquinas de vectores de soporte (SVM) pueden ser efectivos en conjuntos de datos pequeños y de alta calidad, mientras que, en conjuntos de datos grandes y complejos, los algoritmos de aprendizaje profundo pueden ofrecer mejores resultados.
- **Tiempo de entrenamiento y predicción:** El tiempo de entrenamiento y predicción es otro factor crítico para considerar, especialmente en aplicaciones donde se requiere una respuesta en tiempo real. Algoritmos como los árboles de decisión tienden a ser rápidos en términos de entrenamiento y predicción, mientras que los modelos de aprendizaje profundo pueden requerir recursos computacionales significativos y tiempos de entrenamiento más largos.
- **Interpretabilidad de los resultados:** La interpretabilidad de los resultados obtenidos por un algoritmo de clasificación es crucial en muchos casos, especialmente en entornos donde se requiere la aplicabilidad del modelo. Algoritmos como los árboles de decisión y los clasificadores basados en reglas suelen ser más interpretables que los modelos de aprendizaje profundo, lo que los hace más adecuados para aplicaciones donde la transparencia del modelo es una prioridad.

Mejoras y tendencias en los algoritmos de clasificación

Los avances continuos en el campo del aprendizaje automático han dado lugar a mejoras y tendencias emergentes en los algoritmos de clasificación, que incluyen enfoques como los algoritmos de clasificación en línea, el aprendizaje activo y semi-supervisado, y el uso de técnicas de ensemble.

Algoritmos de clasificación en línea

Los algoritmos de clasificación en línea son métodos de aprendizaje automático diseñados para procesar datos de manera incremental, es decir, a medida que llegan nuevos datos. A diferencia de los algoritmos de clasificación tradicionales que requieren el procesamiento de un conjunto de datos completo antes de entrenar el modelo, los algoritmos en línea pueden actualizar continuamente su modelo con cada nueva instancia de datos (He et al., 2019).



Características principales:

1. **Procesamiento en tiempo real:** Los algoritmos de clasificación en línea son ideales para aplicaciones que requieren respuestas rápidas y en tiempo real, ya que pueden adaptarse dinámicamente a los cambios en los datos a medida que se producen.
2. **Eficiencia en el uso de recursos:** Estos algoritmos son eficientes en términos de uso de recursos computacionales y de memoria, ya que no necesitan almacenar todo el conjunto de datos en la memoria para entrenar el modelo.
3. **Adaptabilidad:** Los modelos creados con algoritmos de clasificación en línea son adaptables y pueden ajustarse a medida que cambian las condiciones o características del problema.

Ejemplos de algoritmos de clasificación en línea (Hu et al., 2019):

1. **Perceptrón:** Un ejemplo clásico de un algoritmo de clasificación en línea es el perceptrón, que es un modelo lineal simple que aprende a separar las clases a partir de los datos de entrada, actualizando los pesos de las características con cada nueva instancia.
2. **SGDClassifier (Clasificador de Descenso de Gradiente Estocástico):** Este es un algoritmo de clasificación en línea popular que utiliza el descenso de gradiente estocástico para actualizar iterativamente los pesos del modelo a medida que se presentan nuevas instancias de datos.
3. **Clasificador de Bayes Ingenuo:** Aunque no está diseñado específicamente para el aprendizaje en línea, el clasificador de Bayes ingenuo también puede ser utilizado en un contexto en línea, actualizando sus estimaciones de probabilidad a medida que llegan nuevos datos.

Los algoritmos de clasificación en línea se emplean en diversas aplicaciones donde los datos se generan o cambian de manera continua. Algunos ejemplos incluyen:

1. Detección de fraudes en transacciones financieras.
2. Análisis de sentimientos en redes sociales.
3. Detección de intrusiones en sistemas de seguridad informática.
4. Sistemas de recomendación en tiempo real.

Los algoritmos de clasificación en línea son una herramienta poderosa en el aprendizaje automático, especialmente en aplicaciones que requieren procesamiento en tiempo real y adaptabilidad a datos en constante cambio. Estos algoritmos permiten la construcción de modelos eficientes y precisos que pueden



adaptarse dinámicamente a medida que evolucionan los datos y las condiciones del problema (Merjulah & Chandra, 2019).

Aprendizaje activo y semi-supervisado

En el aprendizaje activo, el modelo selecciona de manera activa las instancias de datos más informativas o inciertas para que un experto humano las etiquete. Estas instancias se seleccionan cuidadosamente de entre un conjunto no etiquetado para maximizar el conocimiento adquirido con cada etiqueta adicional. El objetivo es disminuir la cantidad de datos etiquetados necesarios para entrenar un modelo preciso. Los algoritmos de aprendizaje activo suelen emplear medidas de incertidumbre o diversidad para seleccionar las instancias más útiles para la etiquetación (He et al., 2019).

En el aprendizaje semi-supervisado, el modelo se entrena utilizando tanto datos etiquetados como no etiquetados. Esto permite al modelo aprovechar la información adicional presente en los datos no etiquetados para mejorar su capacidad predictiva. El aprendizaje semi-supervisado es útil cuando la obtención de etiquetas es costosa o difícil, ya que puede aprovechar grandes cantidades de datos no etiquetados disponibles en muchos casos del mundo real. Los algoritmos de aprendizaje semi-supervisado suelen utilizar técnicas de propagación de etiquetas o co-entrenamiento para incorporar información de los datos no etiquetados en el modelo (Xie et al., 2019). Algunas aplicaciones son:

1. Clasificación de imágenes médicas: En la detección de enfermedades, donde las imágenes médicas pueden ser costosas de etiquetar, el aprendizaje activo y semi-supervisado pueden ayudar a reducir la cantidad de imágenes que necesitan ser etiquetadas por expertos.
2. Clasificación de texto: En el análisis de sentimientos o la clasificación de documentos, donde hay grandes cantidades de datos no etiquetados disponibles, el aprendizaje semi-supervisado puede mejorar la precisión del modelo utilizando estos datos.
3. Detección de fraudes: En la detección de transacciones fraudulentas, el aprendizaje activo puede ayudar a identificar transacciones sospechosas para su revisión manual, reduciendo así el número de falsos positivos. .

Ambos enfoques ofrecen ventajas significativas en términos de eficiencia en el etiquetado de datos, generalización del modelo y adaptabilidad a nuevas instancias de datos. Permiten a los modelos aprender de manera más efectiva con menos datos etiquetados, lo que puede ser especialmente útil en aplicaciones



donde obtener etiquetas es costoso o difícil. Además, estos enfoques pueden mejorar la generalización del modelo al aprovechar la información contenida en datos no etiquetados.

Uso de técnicas de ensemble

Las técnicas de ensemble combinan múltiples modelos de clasificación para mejorar el rendimiento predictivo y la robustez del sistema. Métodos como el bagging, el boosting y la votación combinada son ampliamente utilizados en la práctica para reducir el sesgo y la varianza de los modelos individuales, lo que resulta en un rendimiento general más sólido y confiable (Minetto et al., 2019).

La discusión sobre los enfoques de aprendizaje activo y semi-supervisado resalta su relevancia en el ámbito del aprendizaje automático, especialmente en situaciones donde obtener etiquetas de datos es costoso o complejo. Estas metodologías ofrecen soluciones innovadoras para tratar con conjuntos de datos parcialmente etiquetados, aprovechando la interacción estratégica con los datos para mejorar la eficacia del modelo y su capacidad predictiva. La capacidad del aprendizaje activo para seleccionar sabiamente las instancias de datos más informativas o inciertas para la etiquetación humana destaca su potencial para aligerar considerablemente la carga de trabajo asociada con la adquisición de etiquetas, asegurando al mismo tiempo la precisión del modelo.

Por otro lado, el aprendizaje semi-supervisado ofrece una perspectiva adicional al integrar datos no etiquetados en el proceso de entrenamiento del modelo. Esto permite al modelo aprovechar la disponibilidad de datos no etiquetados en muchas situaciones del mundo real, mejorando así su capacidad de generalización y su rendimiento predictivo. La capacidad del aprendizaje semi-supervisado para utilizar eficazmente los datos no etiquetados destaca su importancia en contextos donde la obtención de etiquetas es limitada o costosa, como en la clasificación de imágenes médicas o el análisis de texto (Fang et al., 2019).

La discusión sobre estos enfoques destaca su potencial para mejorar significativamente el rendimiento y la eficiencia de los modelos de aprendizaje automático en una variedad de aplicaciones prácticas. Al combinar de manera estratégica la adquisición selectiva de etiquetas con el aprovechamiento de datos no etiquetados, los enfoques de aprendizaje activo y semi-supervisado ofrecen soluciones versátiles y escalables para afrontar los desafíos asociados con la etiquetación de datos y mejorar la capacidad predictiva de los modelos. De manera general, estas metodologías emergentes representan herramientas valiosas en el campo



del aprendizaje automático, con el potencial de abrir nuevas oportunidades y resolver desafíos en la era del big data.

Discusiones

Los algoritmos de clasificación más implementados en aprendizaje automático comprenden una variedad de métodos que se utilizan para resolver problemas de clasificación en múltiples dominios. Entre los más destacados se encuentran los árboles de decisión, que dividen el espacio de características mediante decisiones en nodos, ofreciendo interpretabilidad y facilidad de uso. Los algoritmos de ensemble, como los random forests y el gradient boosting, combinan múltiples modelos para mejorar la precisión y robustez de las predicciones. Además, las máquinas de vectores de soporte (SVM) son populares por su eficacia en clasificación de alto-dimensionalidad. Otro algoritmo ampliamente utilizado es la red neuronal, que ha ganado relevancia con el auge del aprendizaje profundo, especialmente en tareas complejas como el procesamiento de imágenes y el reconocimiento de voz. Cada uno de estos algoritmos tiene sus propias ventajas y desventajas, lo que permite a los investigadores y profesionales elegir el más adecuado en función del problema específico a resolver.

Las métricas básicas como precisión, sensibilidad y especificidad son fundamentales para evaluar el desempeño de los modelos clasificadores en aprendizaje automático. La precisión indica la proporción de predicciones correctas sobre el total de predicciones realizadas, evidenciando la capacidad del modelo para clasificar adecuadamente las instancias positivas y negativas. Por otro lado, la sensibilidad, también conocida como tasa de verdaderos positivos, mide la capacidad del modelo para identificar correctamente las instancias de la clase positiva entre todas las instancias reales positivas. Finalmente, la especificidad refleja la capacidad del modelo para reconocer instancias negativas de la clase correcta, es decir, la proporción de verdaderos negativos sobre el total de instancias negativas. Estas métricas resultan cruciales para interpretar de manera efectiva el rendimiento de los modelos en tareas de clasificación y proporcionar una base para compararlos entre sí.

Las métricas avanzadas, como el área bajo la curva ROC (*Receiver Operating Characteristic*) y el valor F1, desempeñan un papel esencial en la evaluación de la efectividad de los algoritmos de clasificación. El área bajo la curva ROC mide la capacidad del modelo para discriminar entre las clases positiva y negativa a través de diferentes umbrales de decisión, proporcionando una visión más completa del balance entre



sensibilidad y especificidad. Un valor más alto en esta métrica indica un mejor rendimiento del modelo en términos de clasificación. Por su parte, el valor F1 es una métrica que combina la precisión y la sensibilidad en una única cifra, lo que resulta particularmente útil en situaciones donde se busca un equilibrio entre la identificación de positivas y la reducción de falsos positivos. Estas métricas avanzadas son vitales, ya que permiten a los investigadores y profesionales entender la eficacia de los modelos en contextos más complicados y con conjuntos de datos desbalanceados.

Los algoritmos de clasificación de aprendizaje automático tienen aplicaciones diversas y perspectivas prometedoras en una variedad de contextos. En el ámbito de la salud, estos algoritmos se utilizan para diagnosticar enfermedades a partir de imágenes médicas y datos clínicos, mejorando la precisión y rapidez de los diagnósticos. En el sector financiero, se emplean para la detección de fraudes y la evaluación de riesgos crediticios. En el marketing, ayudan a segmentar a los consumidores y mejorar las recomendaciones de productos. Las aplicaciones en el procesamiento de lenguaje natural, como el análisis de sentimientos y la clasificación de textos, también están en crecimiento. La capacidad de estos algoritmos para aprender de los datos y adaptarse a nuevas situaciones sugiere que seguirán evolucionando y encontrando nuevos usos en áreas emergentes, como la inteligencia artificial explicativa y el aprendizaje federado, lo que potenciará aún más su impacto en la sociedad.

Conclusiones

La revisión de métricas de evaluación en el aprendizaje automático subraya la importancia de seleccionar métricas apropiadas que reflejen con precisión el rendimiento de los modelos. La comprensión y aplicación adecuada de estas métricas son fundamentales para tomar decisiones informadas sobre la selección y ajuste de algoritmos, así como para evaluar su eficacia en diversas aplicaciones del mundo real.

La exploración de algoritmos de clasificación, desde árboles de decisión hasta clasificadores basados en reglas, resalta su versatilidad y aplicabilidad en una amplia gama de problemas. Cada algoritmo tiene sus propias características y ventajas, lo que permite a los practicantes seleccionar el método más adecuado para cada situación específica, ya sea en términos de precisión, interpretabilidad o eficiencia computacional.



La discusión sobre factores a considerar en la selección de algoritmos, como el tamaño y la calidad del conjunto de datos, el tiempo de entrenamiento y la interpretabilidad de los resultados, subraya la importancia de abordar cada problema de manera holística y de considerar las necesidades específicas de la aplicación. La elección del algoritmo adecuado depende de una serie de factores que deben tenerse en cuenta para garantizar el éxito del modelo en la práctica.

La exploración de tendencias y avances en el aprendizaje automático, como los algoritmos en línea y el aprendizaje activo, muestra cómo el campo continúa evolucionando para enfrentar los desafíos emergentes en el análisis de datos. Estos enfoques avanzados proporcionan soluciones innovadoras para problemas específicos, como el procesamiento en tiempo real y la optimización del etiquetado de datos, abriendo nuevas oportunidades para aplicaciones prácticas en una variedad de campos.

Referencias

- Abbas, A., Abdelsamea, M. M., & Gaber, M. M. (2021). Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. *Applied Intelligence*, *51*, 854-864. <https://link.springer.com/article/10.1007/s10489-020-01829-7>
- Abualigah, L., & Diabat, A. (2022). Chaotic binary group search optimizer for feature selection. *Expert Systems with Applications*, *192*, 116368. <https://www.sciencedirect.com/science/article/pii/S0957417421016626>
- Ashraf, M., Zaman, M., & Ahmed, M. (2020). An intelligent prediction system for educational data mining based on ensemble and filtering approaches. *Procedia Computer Science*, *167*, 1471-1483. <https://www.sciencedirect.com/science/article/pii/S1877050920308243>
- Borodulin, A., Gladkov, A., Gantimurov, A., Kukartsev, V., & Evsyukov, D. (2024). Using machine learning algorithms to solve data classification problems using multi-attribute dataset. *BIO Web of Conferences*,
- Chouhan, S. S., Singh, U. P., Sharma, U., & Jain, S. (2024). Classification of different plant species using deep learning and machine learning algorithms. *Wireless Personal Communications*, *136*(4), 2275-2298. <https://link.springer.com/article/10.1007/s11277-024-11374-y>



- Fang, J., Yuan, Y., Lu, X., & Feng, Y. (2019). Robust space–frequency joint representation for remote sensing image scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(10), 7492-7502. <https://ieeexplore.ieee.org/abstract/document/8720267/>
- Hassan, M., Ali, S., Alquhayz, H., & Safdar, K. (2020). Developing intelligent medical image modality classification system using deep transfer learning and LDA. *Scientific Reports*, 10(1), 12868. <https://www.nature.com/articles/s41598-020-69813-2>
- He, N., Fang, L., Li, S., Plaza, J., & Plaza, A. (2019). Skip-connected covariance network for remote sensing scene classification. *IEEE transactions on neural networks and learning systems*, 31(5), 1461-1474. <https://ieeexplore.ieee.org/abstract/document/8759970/>
- Hu, J., Shen, L., & Sun, G. (2019). Squeeze-and-excitation networks. Proceedings of the IEEE conference on computer vision and pattern recognition,
- Kumar, T., Kumar, D., & Singh, G. (2024). Brain tumour classification using quantum support vector machine learning algorithm. *IETE Journal of Research*, 70(5), 4815-4828. <https://www.tandfonline.com/doi/abs/10.1080/03772063.2023.2245350>
- Li, D. (2024). An interactive teaching evaluation system for preschool education in universities based on machine learning algorithm. *Computers in human behavior*, 157, 108211. <https://www.sciencedirect.com/science/article/pii/S0747563224000797>
- Lu, X., Sun, H., & Zheng, X. (2019). A feature aggregation convolutional neural network for remote sensing scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(10), 7894-7906. <https://ieeexplore.ieee.org/abstract/document/8730481/>
- Merjulah, R., & Chandra, J. (2019). Classification of myocardial ischemia in delayed contrast enhancement using machine learning. In *Intelligent data analysis for biomedical applications* (pp. 209-235). Elsevier. <https://www.sciencedirect.com/science/article/pii/B9780128155530000112>
- Minetto, R., Segundo, M. P., & Sarkar, S. (2019). Hydra: An ensemble of convolutional neural networks for geospatial land classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6530-6541. <https://ieeexplore.ieee.org/abstract/document/8698456/>



- Rahmat, T., Ismail, A., & Aliman, S. (2019). Chest X-ray image classification using faster R-CNN. *Malaysian Journal of Computing (MJoC)*, 4(1), 225-236. <https://ir.uitm.edu.my/id/eprint/43820/>
- Silva, J., Borré, J. R., Castillo, A. P. P., Castro, L., & Varela, N. (2019). Integration of data mining classification techniques and ensemble learning for predicting the export potential of a company. *Procedia Computer Science*, 151, 1194-1200. <https://www.sciencedirect.com/science/article/pii/S1877050919306386>
- Sun, H., Li, S., Zheng, X., & Lu, X. (2019). Remote sensing scene classification by gated bidirectional network. *IEEE Transactions on Geoscience and Remote Sensing*, 58(1), 82-96. <https://ieeexplore.ieee.org/abstract/document/8844315/>
- Wei, P., Li, Y., Zhang, Z., Hu, T., Li, Z., & Liu, D. (2019). An optimization method for intrusion detection classification model based on deep belief network. *IEEE Access*, 7, 87593-87605. <https://ieeexplore.ieee.org/abstract/document/8751965/>
- Xie, J., He, N., Fang, L., & Plaza, A. (2019). Scale-free convolutional neural network for remote sensing scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6916-6928. <https://ieeexplore.ieee.org/abstract/document/8699111/>
- Xie, Q., Luong, M.-T., Hovy, E., & Le, Q. V. (2020). Self-training with noisy student improves imagenet classification. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition,
- Zhang, B., Zhang, Y., & Wang, S. (2019). A lightweight and discriminative model for remote sensing scene classification with multidilation pooling module. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(8), 2636-2653. <https://ieeexplore.ieee.org/abstract/document/8746195/>
- Zhao, Z., Islam, F., Waseem, L. A., Tariq, A., Nawaz, M., Islam, I. U., Bibi, T., Rehman, N. U., Ahmad, W., & Aslam, R. W. (2024). Comparison of three machine learning algorithms using google earth engine for land use land cover classification. *Rangeland ecology & management*, 92, 129-137. <https://www.sciencedirect.com/science/article/pii/S1550742423001227>



Zhu, Q., Zhang, P., Wang, Z., & Ye, X. (2019). A new loss function for CNN classifier based on predefined evenly-distributed class centroids. *IEEE Access*, 8, 10888-10895.
<https://ieeexplore.ieee.org/abstract/document/8933403/>

Conflicto de interés

El autor autoriza la distribución y uso de su artículo.

Contribuciones de los autores

La contribución fue realizada íntegramente por el autor José Luis Romero Ibarra.

Financiación

La investigación no requirió fuente de financiamiento.

