



**Somos calidad,
somos USC**

Análisis comparativo de las plataformas no-code Orange y KNIME para la clasificación de especies de pingüinos

Autor

**John Leyder Jaramillo Lucumi
Geimar Shamir Lemus Asprilla
Luis David Mosquera Donado**

Ingeniería De Sistemas

Director

Maritza Palacios Medina

COMBA I+D

Computación ubicua, urbana y móvil

**Facultad de ingeniería
Ingeniería de sistemas
Universidad Santiago de Cali
Santiago de Cali - Colombia
2026**

Resumen

El artículo presenta un estudio comparativo de las herramientas no-code Orange y KNIME, enfocadas en la construcción de modelos predictivos en su entorno, aplicados a la clasificación de especies de pingüinos con el Penguin Dataset como caso de estudio. Se presenta el crecimiento del enfoque no-code en el ámbito del machine learning, lo cual es notable para los entornos educativos y no especializados. Usando la metodología CRISP-DM, se describen las etapas que se llevan a cabo en las dos herramientas: desde la comprensión de los datos hasta la evaluación del modelo. La atención también está en los algoritmos de clasificación, la implementación de Random Forest. El trabajo compara la usabilidad, el tiempo de ejecución y los recursos que poseen las dos herramientas. Se verifica cómo cada entorno o herramienta facilita la construcción de flujo de trabajo sin programar. Este análisis tiene como objetivo servir como una guía metodológica y práctica para los estudiantes interesados en implementar técnicas de machine learning mediante herramientas no-code, así como colaborar en la democratización de la inteligencia artificial para su integración en los procesos de enseñanza-aprendizaje.

Palabras Clave: Aprendizaje automático, Inteligencia artificial, Orange, KNIME

Abstract

This article presents a comparative study of the no-code tools Orange and KNIME, focused on building predictive models in their environment, applied to the classification of penguin species, using the Penguin Dataset as a case study. The growth of the no-code approach in machine learning is presented, which is notable for educational and non-specialized environments. Using the CRISP-DM methodology, the steps carried out in the two tools are described: from data understanding to model evaluation. Focus is also placed on the classification algorithms and the implementation of Random Forest. The paper compares the usability, runtime, and resources of the two tools. It verifies how each environment or tool facilitates the construction of workflows without programming. This analysis aims to serve as a methodological and practical guide for students and teachers interested in implementing machine learning techniques using no-code tools, as well as collaborating in the democratization of artificial intelligence for its integration into teaching and learning processes.

Keywords: Machine Learning, Artificial Intelligence, Orange, KNIME

I. INTRODUCCIÓN

La inteligencia artificial (IA) y el aprendizaje automático (machine learning) han transformado la forma en que se procesan y analizan los datos, extendiéndose más allá de las grandes corporaciones hacia sectores como la salud, la educación y el comercio. Sin embargo, su adopción se ha visto limitada por la necesidad de conocimientos avanzados en programación, lo cual dificulta la participación de estudiantes, docentes y profesionales sin formación técnica en este campo.

En este escenario, las plataformas no-code han adquirido relevancia al permitir la construcción de modelos predictivos mediante interfaces visuales y flujos de trabajo intuitivos, reduciendo barreras técnicas y tiempos de desarrollo. Informes recientes destacan su crecimiento entre 2017 y 2023, con ventajas como la reducción de costos y mayor accesibilidad; aunque persisten desafíos en escalabilidad y mantenimiento (Sundberg et al., 2023; Carroll et al., 2025). Según Gartner (2021), para 2025 el 70 % de las nuevas aplicaciones desarrolladas incorporarán tecnologías low-code o no-code, reflejando la magnitud de esta tendencia a nivel mundial.

Dentro de este panorama, destacan Orange y KNIME, dos plataformas que permiten aplicar machine learning de forma visual. A pesar de su creciente popularidad, la literatura científica ofrece pocos estudios comparativos que analicen a fondo su funcionamiento, especialmente en tareas específicas como la clasificación supervisada. Esta carencia deja un vacío en la toma de decisiones de quienes buscan elegir la herramienta más adecuada para contextos educativos y prácticos.

La presente investigación propone una comparación entre Orange y KNIME utilizando el Penguin Dataset como caso de aplicación, con el objetivo de evaluar su desempeño en términos de precisión, tiempo de ejecución y funcionalidades disponibles. Para ello, se sigue la metodología CRISP-DM, que permite organizar el análisis de manera estructurada desde la comprensión del negocio hasta la evaluación de los resultados.

II. MARCO TEÓRICO

2.1 Aprendizaje automático e inteligencia artificial

La inteligencia artificial tiene múltiples definiciones; se conoce comúnmente como la capacidad de las máquinas para realizar tareas que requieran inteligencia humana, como reconocer patrones o tomar decisiones de manera autónoma (Gignac & Szodorai, 2024).

El aprendizaje automático es un subcampo de la inteligencia artificial que permite que las máquinas aprendan automáticamente a partir de un conjunto de datos, utilizando algoritmos que mejoran el rendimiento del modelo a lo largo del tiempo (Soori, 2023).

Actualmente, el aprendizaje automático tiene aplicaciones en diversas áreas, como la salud, la educación, las finanzas, sistemas inteligentes, etc. Debido a las ventajas que ofrece, como lo son, por ejemplo, el acceso a datos masivos (Soori, 2023).

2.2 Modelos predictivos y clasificación

Los modelos predictivos utilizan conjuntos de datos (datasets) para entrenar y, de esta manera, poder identificar patrones y clasificar nuevas observaciones (Gupta et al., 2023).

La clasificación es una técnica dentro del aprendizaje automático supervisado que asigna una etiqueta a cada observación de acuerdo con los atributos; pueden haber de una o varias clases, y se emplea comúnmente en problemas como la clasificación de especies, como lo muestra un estudio reciente, en donde se aplica modelos de machine learning para diferenciar especies forestales a partir de características morfológicas y ambientales (Loiola et al., 2023).

Para evaluar el desempeño de estos modelos, se utilizan métricas como la matriz de confusión, precisión, recall y f1-score para medir la calidad de las predicciones y ver cómo responde el modelo varios tipos de errores (Aguilar Ruiz & Michalak, 2024).

2.3 Enfoque en el aprendizaje automático sin código

El enfoque sin código implica la creación de modelos predictivos sin necesidad de programar. Esto se logra mediante interfaces y procesos automatizados que realizan las tareas como la preparación, el procesamiento y la evaluación de modelos (Walmart Alice et al., 2025). Este método de creación de modelos proporciona acceso a la inteligencia artificial, permitiendo que personas con conocimientos técnicos limitados inicien proyectos de aprendizaje.

Según Azizi Othman (2025), estas plataformas de no-code han evolucionado rápidamente en los últimos años, priorizando la accesibilidad, agilidad y la reducción del ciclo de desarrollo, lo que ha sido de ayuda para implementar en diferentes sectores.

A pesar de la facilidad que estas herramientas puedan ofrecer, también enfrentan desafíos. Sundberg et al. (2023) menciona que, aunque se reduce la brecha entre los expertos y usuarios de negocio, todavía existen barreras en áreas como implementación, monitoreo y escalabilidad. Alalamin y Uddin (2022) también mencionan que los usuarios suelen encontrar dificultades en la documentación técnica y el manejo de flujos de trabajo más complejos.

2.4 Orange y KNIME

Orange es una plataforma de no-code enfocada en la exploración y enseñanza del aprendizaje automático, la interfaz de widgets conectables logra realizar las tareas como la carga de datos, el procesamiento, la evaluación y la visualización de resultados sin necesidad de escribir código (Orange, s.f.).

KNIME, ofrece un entorno con más de 300 conectores, es compatible con lenguajes de programación con los son R y Python. Su interfaz permite arrastrar y conectar nodos para crear flujos sin programación avanzada; también se destaca por la capacidad para integrarse con herramientas adicionales (Knime, s.f.).

2.5 Penguin dataset

El palmer penguins dataset es un conjunto de datos utilizado en la enseñanza de ciencia de datos. Surge como una alternativa más reciente al ya conocido Iris dataset; de ahí su nombre penguin dataset: The new Iris. Este dataset fue creado por la investigadora Allison Horst, con datos recopilados por el Palmer Station Long Term Ecological Research Program en la Antártida (Horst et al., 2020).

Este conjunto de datos tiene información sobre tres especies de pingüinos: Adelie, Chinstrap y Gentoo, que varían en características como longitud y profundidad del pico, sexo, masa corporal o isla donde se encuentran.

III. ESTADO DEL ARTE:

En un estudio realizado por Rojas et al. (2023), se desarrolló un modelo predictivo para evaluar la capacidad crediticia de los clientes, usando la herramienta Orange. Esta investigación mostró que Orange logró una precisión del 99%, con algoritmos como árboles de decisión.

En el estudio de Alzahrani (2022), se usaron las herramientas de Orange y KNIME para el análisis de comentarios en Instagram en el idioma árabe, con el propósito de detectar casos de ciberacoso; el objetivo principal era identificar de manera automática comentarios abusivos mediante algoritmos de clasificación.

Para este estudio, los comentarios se clasificaron en dos tipos: ciberacoso, tanto el sospechoso como el ya conocido, y el no ciberacoso. En ambas plataformas se usaron los flujos de trabajo para desarrollar los modelos de clasificación; en Knime, se implementó el Rule-Based Row Filter, mientras que en Orange se usó el Select Rows. El estudio concluyó que ambas herramientas fueron eficaces para este tipo de tareas, pero con ciertas diferencias; por ejemplo, Knime permitió una mayor flexibilidad en la configuración de los nodos y el manejo de grandes volúmenes de datos, mientras que, en Orange, la interacción fue más intuitiva y demostró mejor precisión en los resultados cuando eran pocos datos.

Por otro lado, Abuashour et al. (2024) realizaron un estudio comparativo entre las plataformas WEKA, RapidMiner y Orange en la clasificación de algunos conjuntos de datos, entre estos, el popular dataset de Iris. Los resultados de este análisis demostraron que el desempeño de cada modelo va a depender de la herramienta y el dataset utilizado.

A pesar de que hay algunos estudios y documentos donde implementan y comparan distintas plataformas de no-code, aún existe un vacío en la investigación de la evaluación de estas mismas, en especial la comparación de ellas en casos específicos como, por ejemplo, la clasificación de especies. No se ha podido hallar documentación específica de la comparativa de las herramientas de Orange y Knime usando el dataset Penguin como caso para evaluar el desempeño de ambas plataformas.

IV. JUSTIFICACIÓN:

La rápida expansión de la inteligencia artificial (IA) y el aprendizaje automático (machine learning) ha disparado la necesidad de contar con herramientas sencillas que hagan posible crear soluciones predictivas sin tener que escribir código. Para dar respuesta a este desafío, han surgido plataformas no-code como Orange y KNIME, que permiten construir modelos de machine learning utilizando flujos de trabajo visuales y entornos gráficos intuitivos.

Este proyecto se apoya en dos pilares fundamentales: Una justificación práctica, ya que ofrece un análisis comparativo que

puede servir de guía a estudiantes y docentes a la hora de seleccionar plataformas no-code adecuadas para implementar modelos predictivos de forma eficiente, sin necesidad de conocimientos avanzados de programación; y una justificación metodológica, porque examina el proceso de modelado predictivo desde un enfoque alternativo (sin código), evaluando su aplicabilidad técnica mediante el análisis de métricas cuantitativas como la precisión de los modelos, el tiempo de ejecución y la disponibilidad de algoritmos. Esto puede resultar útil para futuras investigaciones centradas en enfoques visuales.

Esta investigación utiliza el Penguin Dataset como caso de aplicación para generar los modelos y analizar sus resultados en términos técnicos sobre el uso de plataformas no-code en tareas de clasificación supervisada. Se espera que los hallazgos contribuyan a la toma de decisiones informadas en el contexto educativo, particularmente en ambientes donde se desea enseñar machine learning sin recurrir a lenguajes de programación.

Por lo tanto, este proyecto se estructura como una investigación de tipo descriptivo, basada en un método comparativo y analítico, y con un enfoque cuantitativo, ya que se centra en la evaluación numérica del rendimiento de los modelos generados en ambas plataformas.

V. PLANTEAMIENTO DEL PROBLEMA

El desarrollo de la inteligencia artificial y el aprendizaje automático en los últimos años ha generado la necesidad de herramientas para construir modelos predictivos sin depender de conocimientos en programación avanzada. En escenarios educativos, por ejemplo, el problema de programar es que dificulta el acceso de estudiantes y profesores al aprendizaje de estas tecnologías. Debido a esta necesidad, han surgido herramientas no-code, como las plataformas: Orange y KNIME, las cuales facilitan la construcción de modelos de machine learning mediante flujos de trabajo e interfaces intuitivas; sin embargo, a pesar de la creciente popularidad, los estudios previos son limitados, ya que no abordan métricas cuantitativas como precisión, tiempo de ejecución o disponibilidad de algoritmos dentro de una metodología estandarizada, desde un enfoque técnico y práctico, específicamente en tareas de clasificación de datos.

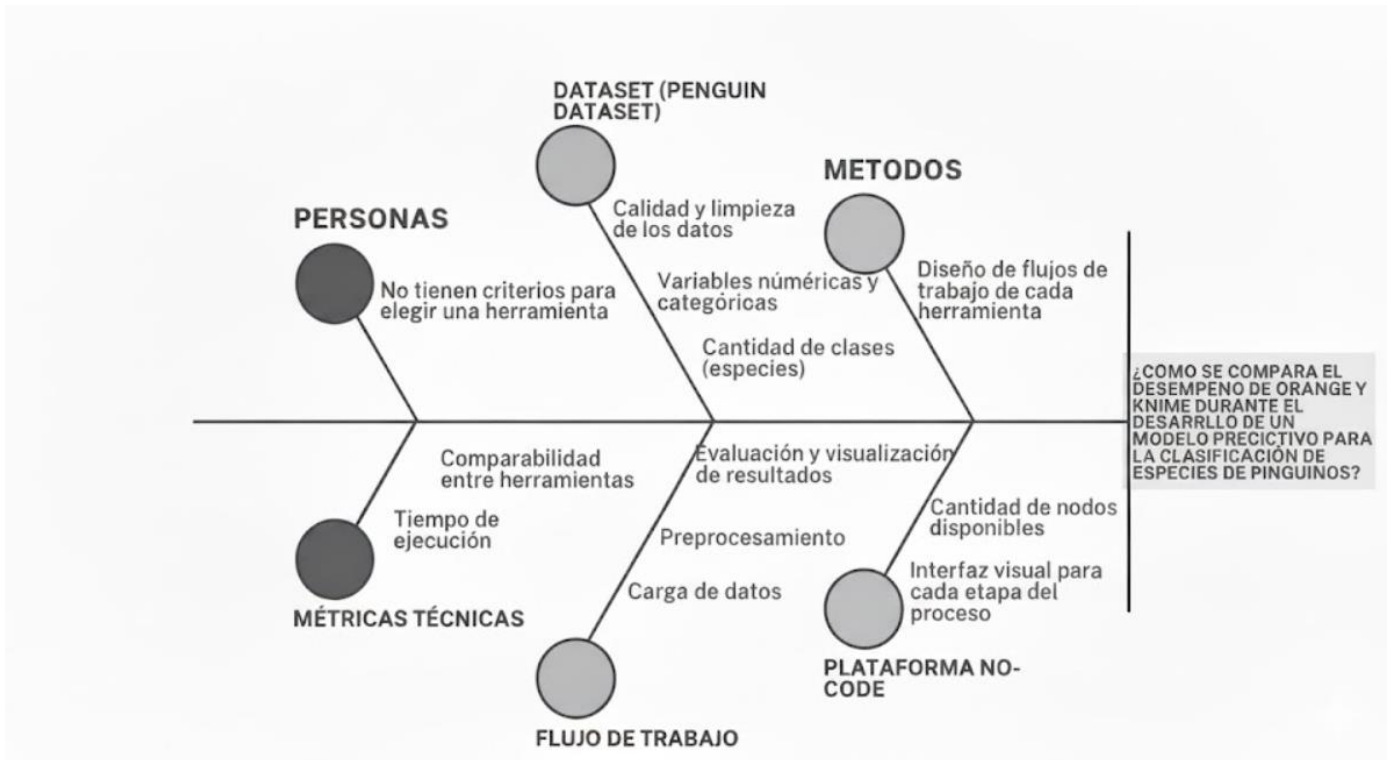
Algunas investigaciones, como la de Cruz Pantano y Romagnano (2022), se enfocan en comparar las funciones generales, sin profundizar ni aplicarlas en casos reales. Dobesová (2024), por ejemplo, muestra que la herramienta Orange tiene un gran potencial para ser usada en el área educativa, pero también afirma que se debe validar dicho potencial mediante prácticas reales. Aunque exista información que compara a Orange y KNIME, la mayoría carece de un enfoque académico y no sigue metodologías estandarizadas como CRISP-DM. Además, muchos de estos análisis no se centran en datasets educativos como lo es el Penguins dataset, que permiten evaluar el desempeño de las herramientas en un escenario realista.

Esto genera la necesidad de un estudio comparativo formal, que se rijan bajo una metodología, para aportar claridad acerca de las debilidades y fortalezas de cada plataforma en contextos educativos y aplicaciones básicas en proyectos de machine learning.

5.1 Pregunta problema

¿Cómo se compara el desempeño de Orange y KNIME durante el desarrollo de un modelo predictivo para la clasificación de especies de pingüinos?

Figura 1. Espina de pescado



Fuente: propia

VI. OBJETIVOS

6.1 Objetivo general

Comparar el desempeño y la facilidad de uso de las plataformas no-code Orange y KNIME, mediante el desarrollo de un modelo predictivo para la clasificación de especies de pingüinos, utilizando el dataset 'penguin dataset: The new Iris'

6.2 Objetivos específicos:

- Describir el procedimiento del diseño y construcción del Modelo en ambas plataformas.
- Comparar el desempeño del Modelo en las plataformas Orange y KNIME en cada una de las fases del proceso de modelado predictivo, utilizando métricas como precisión del modelo, tiempo de ejecución, sensibilidad, y disponibilidad de algoritmos
- Interpretar los resultados de la comparación entre las dos plataformas mediante las métricas establecidas, empleando el Penguin Dataset como caso de estudio de clasificación supervisada.

VII. METODOLOGÍA

Para responder al objetivo, se emplea la metodología de investigación, en conjunto con la metodología CRISP-DM; esta fue seleccionada por su enfoque sistemático y su usabilidad en proyectos de análisis de datos, lo que permite documentar el proceso de forma clara y ordenada.

En la metodología de investigación se emplea 6 fases que son las siguientes:

- Revisión bibliográfica

- Selección del dataset
- Aplicación de la metodología CRISP-DM
- Obtención de métricas de desempeño
- Comparación de resultados
- Interpretación y discusión

7.1.1 Revisión bibliográfica:

En esta fase, se identifican los estudios sobre las plataformas Orange y KNIME u otras plataformas no-code aplicadas al machine learning, con el propósito de consultar y obtener bibliografía útil para el artículo de revisión.

7.1.2 Selección del dataset:

Para el desarrollo de este estudio se seleccionó el Penguin Dataset de Palmer, un conjunto de datos ampliamente utilizado en entornos académicos por tener una estructura limpia y su objetivo multiclase. El dataset contiene información sobre tres clases de pingüinos: Adelie, Gentoo y Chinstrap, recolectada en distintas islas de la Antártida.

Se eligió este por dos razones: primero, su facilidad de uso, por lo que se puede integrar a los flujos de trabajo en cada plataforma sin necesidad de procesamiento complejo; y segundo, las características que posee permiten evaluar el desempeño de los algoritmos en un entorno controlado, lo que lo hace ideal para el propósito comparativo del artículo.

7.1.3 Aplicación de la metodología CRISP-DM:

Se aplica las 6 fases de la metodología CRISP-DM: comprensión del negocio, comprensión de los datos, preparación de los datos, modelado, evaluación y despliegue.

7.1.3.1 Comprensión del negocio:

Aquí se establece el objetivo, el cual es comparar el desempeño de Orange y KNIME en una tarea de clasificación.

7.1.3.2 Comprensión de los datos:

En esta fase, se realiza el análisis del Penguin Dataset, observando las variables disponibles:


Tabla 1. Variables

| Nombre | Tipo |
|-------------------|-------------|
| Species | categorical |
| island | categorical |
| culmen_length_mm | Numeric |
| culmen_depth_mm | Numeric |
| flipper_length_mm | Numeric |
| Body_mass_g | Numeric |
| sex | categorical |

En ambas plataformas se importa el archivo .CSV.

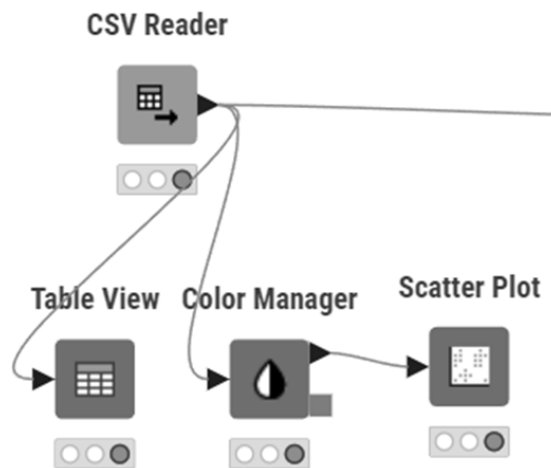
En Orange se emplea el widget CSV File Import, seguido de Data table y scatter plot, para tener una exploración visual.

Figura 2. Widgets de visualización del dataset en Orange



En KNIME se emplea el nodo CSV Reader, seguido de Table View y scatter plot, para obtener diagnóstico similar.

Figura 3. Nodos de visualización del dataset en KNIME



7.1.3.3 Preparación de los datos:

Se lleva a cabo el proceso de limpieza de los datos, escoger los atributos relevantes y descartar aquellos que alterarían la tarea de entrenamiento y clasificación. Sin embargo, no se realiza el trabajo de limpieza y selección de los datos, el penguin dataset contiene atributos que están cuidadosamente seleccionados para el aprendizaje supervisado. Todas las variables fueron consideradas relevantes para la tarea de clasificación, por lo que fueron conservadas tanto en Orange como KNIME para asegurar una igualdad de condiciones.

7.1.3.4 Modelado:

En esta fase se construye los modelos de clasificación, utilizando algoritmos iguales en ambas plataformas. Para esta comparativa se usa Random Forest. Se ajustan los parámetros en cada una de manera que, al igual que en la preparación de los datos, ambas plataformas estén en condiciones similares.

Figura 4 Modelo de clasificación en Orange

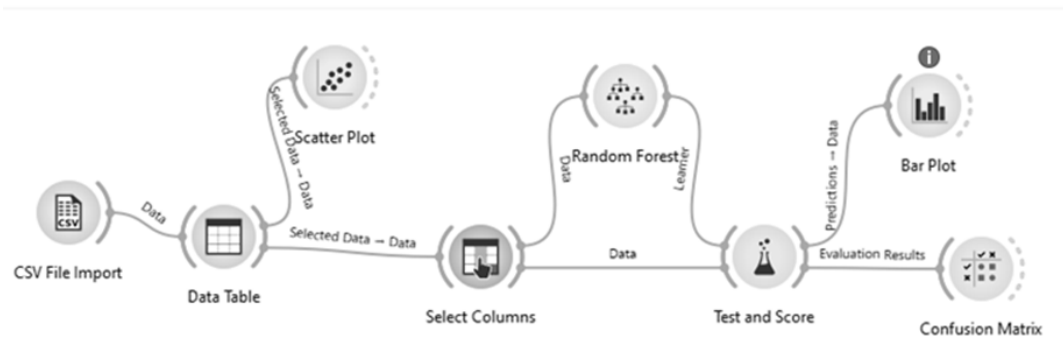
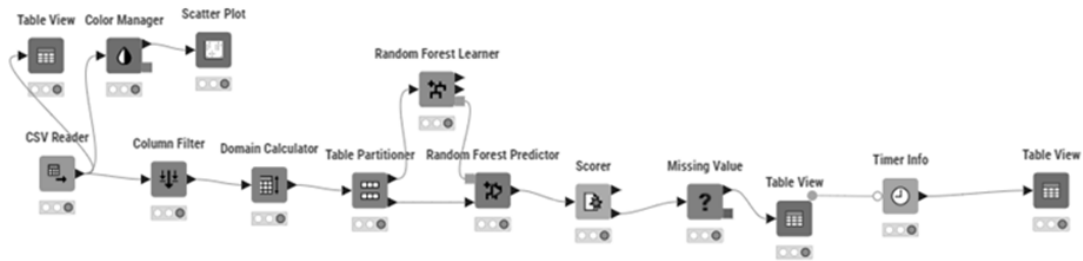


Figura 5 Modelo de clasificación en KNIME



7.1.3.5 Evaluación:

Para la evaluación se emplearon los respectivos nodos o widgets para cada plataforma.

En Orange, se emplea el widget Test and Score.

Figura 6. widget Test and Score de Orange



En KNIME, se emplea el nodo Score.

Figura 7. Nodo Score de KNIME



Se obtienen los datos de AUC, ACCUARY, F1, PRECISION Y RECALL para Orange, y RECALL, PRECISION, SENSITIVITY, F-MEASURE Y ACCURACY para KNIME.

Para cada plataforma, se tomaron los datos del tiempo de ejecución, tanto para el entrenamiento como para la clasificación.

Para KNIME, los tiempos fueron los siguientes:

Tabla 2. Métricas de tiempo del modelo en KNIME

| Fase | tiempo |
|-------------------------|---------------|
| Random Forest Learner | 0.71 segundos |
| Random Forest Predictor | 0.41 segundos |

Y los resultados de las métricas fueron las siguientes:

Tabla 3. Métricas de desempeño del modelo en KNIME

| Métrica | Puntaje |
|-------------|-----------|
| RECALL | 0.706=70% |
| PRECISION | 0.896=90% |
| SENSITIVITY | 0.706=70% |
| F-MEASURE | 0.709=71% |
| ACCURACY | 0.812=81% |

Para Orange, los tiempos fueron los siguientes:

Tabla 4. Métricas de tiempo del modelo en Orange

| Fase | tiempo |
|---------------------|----------------|
| Random Forest Train | 0.344 segundos |
| Random Forest Test | 0.046 segundos |

Y estos fueron los resultados de las métricas:

Tabla 5. Métricas de desempeño del modelo en ORANGE.

| Métrica | Puntaje |
|-----------|-----------|
| AUC | 0.999=99% |
| ACCURACY | 0.988=98% |
| F1 | 0.988=98% |
| PRECISION | 0.988=98% |
| RECALL | 0.988=98% |

7.1.3.6 Despliegue:

Por último, los resultados obtenidos en las métricas fueron documentados y se generó unas visualizaciones que permiten

comparar el desempeño del modelo en ambas plataformas.


Para Orange, se utilizó los widgets de Distributions y confusión Matrix.

Figura 8. Widgets Confusion Matrix y Distributions de Orange



Para KNIME, se empleó los nodos de Bar chart y el mismo Scorer, que nos da el resultado en una matriz de confusión.

Figura 9. Nodos Bar Chart y Scorer de KNIME



7.1.4 Obtención de métricas de desempeño:

En esta fase se recopilan los resultados obtenidos en la fase 5 de la metodología CRISP-DM. Como se ha mencionado en el artículo, se han elegido métricas para la medición del desempeño de cada plataforma, como la precisión, recall, F1-score, tiempo de ejecución, etc. Las cuales destacan por su relevancia en la evaluación de los algoritmos de clasificación y pueden ser fácilmente interpretables en contextos académicos. Estos resultados fueron registrados en la fase 6 de la metodología CRISP-DM para su posterior análisis y comparación.

7.1.5 Comparación de resultados:

Una vez obtenidas los resultados de las métricas, se realiza un análisis comparativo con el objetivo de encontrar similitudes, diferencias, ventajas y desventajas entre Orange y KNIME.

7.1.5.1 Comparativa de Plataformas No-Code: Orange vs. KNIME:

- Tiempos de Ejecución (Random Forest):

KNIME:

- Random Forest Learner (Entrenamiento): 0.71 segundos
- Random Forest Predictor (Clasificación): 0.41 segundos

Tiempo total aproximado: 1.12 segundos

Orange:

- Random Forest Train (Entrenamiento): 0.344 segundos
- Random Forest Test (Clasificación): 0.046 segundos

Tiempo total aproximado: 0.39 segundos

Orange muestra tiempos de ejecución más rápidos para el entrenamiento y la clasificación del modelo Random Forest en comparación con KNIME. Esto nos dice que hay una mayor eficiencia computacional en este caso específico.

Tabla 6. Comparación entre resultados de las métricas

| Métrica | Resultado KNIME | Resultado Orange |
|-------------|-----------------|------------------|
| RECALL | 0.706 ≈ 70% | 0.988 ≈ 98% |
| PRECISION | 0.896 ≈ 90% | 0.988 ≈ 98% |
| ACCURACY | 0.812 ≈ 81% | 0.988 ≈ 98% |
| F1 | N/A | 0.988 ≈ 98% |
| SENSITIVITY | 0.706 ≈ 70% | N/A |
| F-MEASURE | 0.709 ≈ 71% | N/A |
| AUC | 0.75 ≈ 75% | 0.999 ≈ 99% |

- **RECALL:** Orange muestra un Recall mucho más alto en comparación con KNIME, lo que indica que identifica una proporción significativamente mayor de casos positivos reales.
- **PRECISION:** Orange supera a KNIME en Precisión, lo que significa que de los casos que predice como positivos, una mayor parte son realmente positivos.
- **ACCURACY:** La exactitud general de Orange es considerablemente superior, lo que nos dice que su modelo realiza predicciones correctas en un porcentaje mayor de los casos totales.
- **F1:** el F1 es más alto en Orange, lo que confirma un mejor rendimiento general en el equilibrio entre falsos positivos y falsos negativos

- SENSITIVITY: La sensibilidad en KNIME es equivalente al Recall de Orange, que no se proporciona explícitamente para Orange, pero dado su alto Recall, se esperaría un valor similarmente alto
- F-MEASURE: F-Measure es otra forma de referirse al puntaje F1, y en KNIME es del 71%, dejando en evidencia la superioridad de Orange.
- AUC Orange tiene un resultado AUC muy alto, lo que nos muestra una excelente capacidad del modelo para distinguir entre clases, en paralelo, KNIME presenta un porcentaje más cercano a 0.50, lo que indica que el modelo tiende a una clasificación aleatoria.

7.1.6 Interpretación y discusión:

7.1.6.1 Rendimiento del Modelo:

Basado en las métricas elegidas, Orange demuestra un rendimiento superior en todas las métricas comunes (Recall, Precision, Accuracy, F1) con valores cercanos al 98-99% y Su AUC es de 0.999, lo cual es un excelente resultado. KNIME, aunque presenta resultados decentes (Recall 70%, Precision 90%, Accuracy 81%, F1 71%), se queda atrás en comparación.

Cabe aclarar que, para el caso de la plataforma KNIME, se presentaron algunos problemas a la hora de trabajar con el dataset, encontrándonos con datos perdidos en algunas ocasiones, razón por la cual se tuvo que manipular el dataset con distintos nodos como el Missing Value para reducir esa pérdida. Debido a esto, el modelo se vio afectado a la hora de hacer el entrenamiento y la clasificación.

Además, se identificó que, para el caso de KNIME, su flujo de trabajo es más robusto en comparación con Orange. Concluimos que se debe tener conocimiento previo sobre esta plataforma para su buen uso, mientras que, en Orange, la forma en la que se construye el flujo es más intuitiva y amigable; sin embargo, no ofrece las opciones de personalización y de ajustes en los parámetros como lo tiene KNIME.

7.1.6.2 Eficiencia Computacional:

Orange también muestra una mayor eficiencia en los tiempos de ejecución para el modelo Random Forest, completando las tareas de entrenamiento y prueba en una fracción del tiempo que le toma a KNIME.

VIII. CONCLUSIONES

El análisis comparativo entre Orange y KNIME mostró que, aunque ambas plataformas son buenas opciones para crear modelos predictivos sin la necesidad de programar, tienen diferencias en el rendimiento. Orange fue más rápido en su ejecución y tiene una interfaz sencilla, lo que la hace ideal para entornos educativos y para usuarios con poca experiencia. KNIME, en cambio, ofreció opciones avanzadas para la personalización y manejo de parámetros, siendo más adecuada para proyectos que necesitan un control más detallado del proceso.

Para este caso en particular, Orange tuvo un mejor desempeño que KNIME, tal y como señaló Alzahrani (2022), Orange, es más preciso cuando son pequeños volúmenes de datos. Es importante considerar que los resultados pueden estar influenciados por factores como la configuración por defecto de los algoritmos, el manejo interno de los datos en cada plataforma y la estructura del dataset utilizado, por lo que no se podría afirmar de manera absoluta que Orange sea superior a KNIME en todos los contextos. Puede que, en un entorno donde el dataset sea de mayor tamaño, KNIME destaque sobre Orange.

Los resultados usando el conjunto de datos Penguin dataset, demuestran que un enfoque no-code funciona bien para introducir el aprendizaje automático a quienes no son expertos, sin que se reduzca la calidad del análisis. Además, usar la metodología CRISP-DM ayudó a organizar el proceso de forma clara, aportando rigor al estudio. Para futuras investigaciones, se recomienda incluir otros algoritmos, datasets y escenarios en las comparaciones, para que así se creen guías que ayuden a usar herramientas no-code en entornos académicos.

IX. REFERENCIAS

- Aguilar-Ruiz, J. S., & Michalak, M. (2024). Classification performance assessment for imbalanced multiclass data. *Scientific Reports*, 14(1), 1–10. <https://doi.org/10.1038/S41598-024-61365-Z;SUBJMETA>
- Ajimati, M. O., Carroll, N., & Maher, M. (2025). Adoption of low-code and no-code development: A systematic literature review and future research agenda. *Journal of Systems and Software*, 222, 112300. <https://doi.org/10.1016/J.JSS.2024.112300>
- Alamin, M. A. al, & Uddin, G. (2022). Challenges and Barriers of Using Low Code Software for Machine Learning. <https://arxiv.org/pdf/2211.04661>
- Alzahrani, S. (2022). Data Mining Regarding Cyberbullying in the Arabic Language on Instagram Using KNIME and Orange Tools. *Engineering, Technology & Applied Science Research*. <https://doi.org/10.48084/etasr.5184>.
- Cruz Pantano, J., & Romagnano, M. (2022). Business Intelligence and Analytics Assisted by Free Software Tools. *International Journal of Combinatorial Optimization Problems and Informatics*, 13(2), 14–32. <https://doi.org/10.61467/2007.1558.2022.V13I2.260>
- Dobesova, Z. (2024). Evaluation of Orange data mining software and examples for lecturing machine learning tasks in geoinformatics. *Computer Applications in Engineering Education*, 32(4), e22735. <https://doi.org/10.1002/CAE.22735>
- Gartner Reprint. (n.d.). https://www.gartner.com/doc/reprints?id=1-2LJ2SZQ2&ct=250725&st=sb?utm_source=marketo&utm_medium=email&utm_campaign=Report:%20Gartner-LCAP-MQ-2025-English
- Gignac, G. E., & Szodorai, E. T. (2024). Defining intelligence: Bridging the gap between human and artificial perspectives. *Intelligence*, 104, 101832. <https://doi.org/10.1016/J.INTELL.2024.101832>
- Gupta, P., Bagchi, A. (2024). Machine Learning. In: *Essentials of Python for Artificial Intelligence and Machine Learning*. Synthesis Lectures on Engineering, Science, and Technology. Springer, Cham. https://doi.org/10.1007/978-3-031-43725-0_8
- Gupta, R., Sharma, A., & Alam, T. (2024). Building Predictive Models with Machine Learning. *Studies in Big Data*, 145, 39–59. https://doi.org/10.1007/978-981-97-0448-4_3
- Horst, A. M., Hill, A. P., & Gorman, K. B. (2020). palmerpenguins: Palmer Archipelago (Antarctica) penguin data (Version 0.1.0) [R package]. <https://allisonhorst.github.io/palmerpenguins/> <https://doi.org/10.5281/zenodo.3960218>
- Joshi, A. v. (2023). Classification. *Machine Learning and Artificial Intelligence*, 225–234. https://doi.org/10.1007/978-3-031-12282-8_18
- La metodología CRISP-DM en ciencia de datos - IIC. (n.d.) <https://www.iic.uam.es/innovacion/metodologia-crisp-dm-ciencia-de-datos/>
- Loiola, T. M., Fantinel, R. A., dos Santos, F. D., de Bastos, F., Schuh, M. S., Fernandes, P., ... Pereira, R. S. (2023). Use of Machine Learning Algorithms in the Classification of Forest Species. *Anuário Do Instituto De Geociências*, 46. https://doi.org/10.11137/1982-3908_2023_46_50490
- (PDF) No-Code AI Meets Big Data Democratizing Machine Learning in the Cloud Era. (n.d.) https://www.researchgate.net/publication/392696698_No-

Code_AI_Meets_Big_Data_Democratizing_Machine_Learning_in_the_Cloud_Era

- (PDF) No-Code/Low-Code Platforms: Democratizing AI Development for Non- Experts. (n.d.) https://www.researchgate.net/publication/389857094_No-CodeLow-Code_Platforms_Democratizing_AI_Development_for_Non-Experts
- Orange Data Mining. (n.d.) <https://orangedatamining.com/>
- Open for Innovation | KNIME. (n.d.) <https://www.knime.com/>
- Rojas, Grecia & Carreño, Schleiffer & Ovalle, Christian & Chávez, Erick. (2023). Intelligent predictive model applying Data Mining strategies for a credit evaluation of a commercial company. 10.18687/LACCEI2023.1.1.1148
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A Systematic Literature Review on Applying CRISP-DM Process Model. *Procedia Computer Science*, 181, 526–534. <https://doi.org/10.1016/J.PROCS.2021.01.199>
- Shimaoka, A. M., Ferreira, R. C., & Goldman, A. (2024). The evolution of CRISP-DM for Data Science: Methods, Processes and Frameworks. *SBC Reviews on Computer Science*, 4(1), 28–43. <https://doi.org/10.5753/reviews.2024.3757>
- Soori, M., Arezoo, B., & Dastres, R. (2023). Artificial intelligence, machine learning and deep learning in advanced robotics, a review. *Cognitive Robotics*, 3, 54–70. <https://doi.org/10.1016/J.COGR.2023.04.001>
- Ahmad Abuashour*, Mowafaq Salem Alzboon and Muhyeeddin Kamel Alqaraleh, Comparative Study of Classification Mechanisms of Machine Learning on Multiple Data Mining Tool Kits. *Am J Biomed Sci & Res.* 2024 - 22(1). AJBSR.MS.ID.002913. DOI:10.34297/AJBSR.2024.22.002913
- Sampieri, R. H., Collado, C. F., & Lucio, P. B. (2010). *Metodología de la investigación*. McGraw-Hill Interamericana. <http://148.202.167.116:8080/jspui/handle/123456789/2707>