

# Inteligencia Artificial Explicable en una Aplicación en Sistemas de Recomendación

## Explainable Artificial Intelligence in an Application in Recommendation Systems

Miguel Molina Villacís<sup>1</sup>, María Molina Miranda<sup>2</sup>, Ximena Acaro Chacón<sup>3</sup>, Angel Jiménez Villao<sup>4</sup>, y Darla Luna Chiriboga<sup>5</sup>

### RESUMEN

**Contexto:** Este artículo se centra en el desarrollo de técnicas interpretativas para un sistema de recomendación basado en Inteligencia Artificial (IA) aplicado a procesos de contratación pública. El proyecto busca no solo implementar soluciones técnicas, sino también abordar desafíos estructurales y organizacionales en la contratación, mejorando la eficiencia y la justicia. **Método:** Se destaca el crecimiento exponencial de la dependencia tecnológica en diversos sectores, impulsada por avances en IA y Machine Learning, y la adopción de la Inteligencia Artificial Explicable (XAI). **Resultados:** El proyecto ofrece como resultado un algoritmo predictivo para el proceso de compras públicas. A diferencia de la IA tradicional, la XAI equilibra la precisión con la interpretabilidad humana, crucial para su aplicación en sistemas de recomendación. **Conclusiones:** Este enfoque holístico tiene como objetivo mejorar la transparencia, confianza y eficiencia en la selección de proveedores, abordando la capacidad y los riesgos de sesgo en la toma de decisiones automatizada, y resaltando la importancia de la XAI en la creación de sistemas más éticos y confiables.

**Palabras clave:** Sistema recomendación, Algoritmo, Prototipo, Predicción, Machine learning, Licitaciones

### ABSTRACT

**Context:** This article focuses on the development of interpretive techniques for a recommendation system based on Artificial Intelligence (AI) applied to public procurement processes. The project seeks not only to implement technical solutions, but also to address structural and organizational challenges in procurement, improving efficiency and fairness. **Method:** The exponential growth of technological dependence in various sectors is highlighted, driven by advances in AI and Machine Learning, and the adoption of Explainable Artificial Intelligence (XAI). **Results:** The project offers as a result a predictive algorithm for the public procurement process. Unlike traditional AI, XAI balances precision with human interpretability, crucial for its application in recommendation systems. **Conclusions:** This holistic approach aims to improve transparency, trust and efficiency in supplier selection, addressing capacity and risks of bias in automated decision making, and highlighting the importance of XAI in creating more ethical systems and reliable.

**Keywords:** Recommendation system, Algorithm, Prototype, Prediction, Machine learning, Tenders

**Fecha de recepción:** Enero 14, 2024

**Fecha de aceptación:** Septiembre 30, 2024

### Introducción

En la actualidad, el aumento de la dependencia de los diferentes sectores empresariales de la tecnología ha experimentado un crecimiento exponencial en los últimos años. Impulsadas por los nuevos avances tecnológicos como la Inteligencia Artificial (IA), muchas empresas han cambiado su modelo y gestión de trabajo hacia el desarrollo automatizado, utilizando modelos predictivos como el Aprendizaje Automático (Machine Learning) y la Inteligencia Artificial Explicable (XAI). Esto tiene como objetivo optimizar procesos y gestionar tiempo y recursos de manera más eficiente (Janiesch et al., 2021).

En este contexto, surge el concepto de Inteligencia Artificial Explicable (XAI), que se centra en el desarrollo de técnicas y herramientas que permiten comprender y explicar el razonamiento detrás de las decisiones de los sistemas de IA (Mimbrera, 2021). A diferencia de la IA tradicional, que se enfoca en la precisión y el rendimiento, la XAI busca equilibrar la precisión con la comprensión humana.

Según investigaciones recientes (Alcarazo, 2022), el uso de sistemas basados en IA a menudo carece de aplicabilidad,

lo que implica permitir que los usuarios comprendan los fundamentos detrás de las predicciones de los sistemas de IA. Este problema ha impulsado el desarrollo de la IA explicable (XAI), y se han propuesto diversos métodos para construir explicaciones. Varios de estos métodos recurren a generar visualizaciones que apoyen la explicación. Por lo tanto, XAI no solo implica conocimientos de IA como el sistema que se utilizará o los algoritmos que se explicarán, sino que también se necesitarán conocimientos para diseñar e implementar visualizaciones adecuadas (Pathak, 2024).

<sup>1</sup>Universidad de Guayaquil. E-mail: miguel.molinav@ug.edu.ec

<sup>2</sup>Universidad de Guayaquil. E-mail: maria.molinam@ug.edu.ec

<sup>3</sup>Universidad de Guayaquil. E-mail: ximena.acaroc@ug.edu.ec

<sup>4</sup>Universidad de Guayaquil. E-mail: angel.jimenezv@ug.edu.ec

<sup>5</sup>Universidad de Guayaquil. E-mail: darla.lunac@ug.edu.ec



This work is licensed under a Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International Licence.

**Cómo citar:** Molina, M., Molina, M., Acaro, X., Jiménez, A., & Luna, D. (2025). Inteligencia Artificial Explicable en una Aplicación en Sistemas de Recomendación. *Ecuadorian Science Journal*, 8(2), 1–8, Septiembre–2025. DOI: <https://doi.org/10.46480/esj.8.2.180>

El objetivo del presente proyecto es desarrollar técnicas de interpretación usando herramientas específicas para comprender el modelo de inteligencia artificial para un sistema de recomendaciones en el contexto de las licitaciones públicas. Esto nos ayudará a mejorar la comprensión y la confianza en los sistemas de recomendación al proporcionar explicaciones claras y comprensibles sobre cómo se generan las recomendaciones. En este documento, exploraremos el concepto de XAI y su aplicación específica en los sistemas de recomendación, destacando su importancia en la creación de sistemas más transparentes, éticos y confiables.

Trabajos Relacionados

La inteligencia artificial explicable (XAI) se ha convertido en un campo de investigación crítico dentro del desarrollo de sistemas de recomendación (Fonseca, 2021). Estos sistemas, que son esenciales en la toma de decisiones tanto en entornos comerciales como públicos, dependen de la capacidad de ofrecer explicaciones comprensibles sobre cómo se generan sus recomendaciones. Estudios recientes (Gonzalo, 2022) en “Evaluación de Modelos de Inteligencia Artificial Explicable. Caso de Uso con Clasificadores de Licitaciones Públicas a partir de Textos”, indican que la aplicación de XAI permite explorar y comparar diversos enfoques, algoritmos y técnicas utilizadas en la literatura para mejorar la transparencia y la confiabilidad de estos sistemas.

La evaluación de sistemas de inteligencia artificial explicable puede abordarse desde diferentes enfoques, dependiendo de la complejidad del modelo y del momento en que se generan las explicaciones: antes o después de la creación del modelo (Gonzalo, 2022). Esto subraya la relevancia de seleccionar técnicas adecuadas de filtrado colaborativo y explicabilidad (Valenzuela et al., 2022) que permitan a las empresas no solo optimizar sus procesos, sino también asegurar que las decisiones automatizadas sean comprensibles para los usuarios.

En este contexto, la XAI no solo busca mejorar la transparencia de los modelos, sino que también se enfoca en incrementar la confianza del usuario al poder justificar las recomendaciones proporcionadas (Counago, 2021). La implementación de métodos explicativos adecuados en los sistemas de recomendación resulta crucial, especialmente en sectores como el público, donde la rendición de cuentas y la optimización de procesos son prioritarias (Hernández, 2020).

La Tabla 1 detalla un análisis de las causas y consecuencias del problema identificado en los procesos de contratación pública del Servicio Nacional de Contratación Pública (SERCOP) en Ecuador, así como las implicaciones de la propuesta de utilizar la Inteligencia Artificial Explicable (XAI) en sistemas de recomendación.

Contribución Principal

La principal contribución de este proyecto es el desarrollo de un sistema de recomendación basado en Inteligencia Artificial Explicable (XAI) aplicado al contexto de licitaciones públicas en Ecuador. Este sistema busca mejorar la transparencia, equidad y eficiencia en los procesos de contratación pública, proporcionando explicaciones claras

Tabla 1. Análisis de Causas y Consecuencias en Contratación Pública

| CAUSAS                                                | CONSECUENCIAS                                                                                                                                                                                                                                                          |
|-------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Complejidad de los procesos de licitación             | Los errores en las especificaciones técnicas de las licitaciones pueden resultar en la asignación incorrecta de recursos públicos, lo que afecta la eficiencia y efectividad de los programas y proyectos gubernamentales.                                             |
| Falta de capacitación y certificación                 | La opacidad en los sistemas de recomendación y la presencia de errores técnicos pueden socavar la confianza del público en la integridad y equidad de los procesos de contratación pública, lo que puede afectar la legitimidad y credibilidad del gobierno.           |
| Opacidad en los sistemas de recomendación             | La presencia de errores técnicos y la falta de transparencia en los procesos de contratación pueden favorecer la participación de proveedores extranjeros en detrimento de los proveedores nacionales, lo que puede afectar la economía local y la creación de empleo. |
| Sesgos y discriminación en los datos de entrenamiento | Presentaría la presencia de sesgos en los sistemas de recomendación puede llevar a decisiones injustas o discriminatorias en los procesos de contratación, lo que afecta la equidad y justicia en la distribución de recursos y oportunidades.                         |

y comprensibles de las recomendaciones generadas, lo que permite a los usuarios entender y confiar en las decisiones automatizadas.

Las principales contribuciones de nuestro artículo son:

- Desarrollar técnicas de interpretación usando herramientas específicas para comprender el modelo de inteligencia artificial
- Crear visualizaciones comprensibles que sean intuitivas y comprensibles para los usuarios
- Evaluar cómo las técnicas de XAI afectan a la efectividad y aceptación hacia el usuario

Definición del Proyecto

El proyecto consiste en la implementación de un sistema de recomendaciones utilizando técnicas de Machine Learning e Inteligencia Artificial Explicable (XAI) para optimizar los procesos de licitación pública. Se enfoca en mejorar la transparencia y comprensión de las decisiones automatizadas, abordando problemas de opacidad y sesgo en la selección de proveedores. El sistema emplea datos de empresas del sector IT, que son preprocesados para garantizar su calidad, y utiliza herramientas de código abierto como Python y TensorFlow.

## Fase de Medición

En la fase de medición, se utilizaron diversas técnicas para evaluar el rendimiento y la precisión del modelo de XAI desarrollado. La fase de medición se centró en evaluar el impacto del sistema de Inteligencia Artificial Explicable (XAI) en los procesos de licitación pública mediante la implementación de pruebas exhaustivas y la recopilación de datos cuantitativos y cualitativos.

Se realizó una validación cruzada utilizando un conjunto de datos históricos de licitaciones públicas. El modelo de XAI fue entrenado y probado en diferentes particiones de los datos para evaluar su capacidad predictiva y la consistencia de sus recomendaciones. Los resultados mostraron una tasa de precisión del 92%, superando los métodos tradicionales utilizados en el pasado.

Se realizaron pruebas adicionales con nuevos datos para medir la capacidad del sistema en la generación de recomendaciones precisas. El rendimiento se mantuvo estable, confirmando la robustez del algoritmo desarrollado.

Se implementaron encuestas dirigidas a los usuarios del sistema, incluidos responsables de contrataciones públicas y expertos en licitaciones, para medir su percepción sobre la transparencia del proceso. La interfaz explicable del sistema permitió a los usuarios explorar cómo se generaban las recomendaciones, lo que resultó en un aumento significativo en la comprensión del proceso.

Para evaluar la efectividad del sistema de recomendación basado en inteligencia artificial explicable (XAI) enfocado en minimizar el gasto público en desarrollo, se diseñó una encuesta para recopilar la percepción de los usuarios en relación a diversos parámetros, como la facilidad de uso, la utilidad de la información, la precisión de las recomendaciones y la capacidad del sistema para reducir costos.

## Análisis de los Datos Obtenidos

Se llevó a cabo tras un proceso de recolección y procesamiento meticuloso. Los datos fueron generados y simulados para garantizar un amplio rango de escenarios posibles que el sistema de recomendación pudiera enfrentar. Estos datos incluyeron características clave como precios, calificaciones de calidad, tiempos de entrega y otros indicadores relevantes de proveedores, los cuales fueron luego preprocesados para asegurar su integridad y consistencia.

El preprocesamiento de los datos involucró la imputación de valores faltantes, codificación de variables categóricas y escalado de características, lo que permitió al modelo de machine learning trabajar con un conjunto de datos limpio y balanceado. Una vez completado el preprocesamiento, los datos se dividieron en conjuntos de entrenamiento y prueba, asegurando una validación adecuada del modelo.

Durante la fase de entrenamiento, se aplicó un algoritmo de Random Forest para aprender de los patrones presentes en los datos (Rojo, 2019). Posteriormente, los datos procesados y las predicciones del modelo fueron analizados para determinar la precisión y utilidad de las recomendaciones generadas. La evaluación incluyó el cálculo de probabilidades y la generación de gráficos

comparativos que permitieron una visualización clara de las diferencias y similitudes entre los proveedores evaluados.

Los resultados del análisis mostraron que el sistema era capaz de identificar patrones significativos y ofrecer recomendaciones precisas, con una alta tasa de acierto en la predicción de la mejor opción entre los proveedores. Además, los gráficos generados proporcionaron una representación visual efectiva de los datos, facilitando la comprensión de las fortalezas y debilidades de cada proveedor según los criterios establecidos (Fonseca and Cornelio, 2022). Esto permitió concluir que el sistema no solo es robusto en su capacidad de predicción, sino también en su capacidad para ofrecer recomendaciones claras y útiles para la toma de decisiones informadas.

## Metodología

### Mecanismos para la Elaboración del Prototipo

El desarrollo del prototipo del sistema de recomendación se realizó utilizando una metodología ágil, específicamente Scrum, que permitió iterar rápidamente sobre el diseño y las funcionalidades. Se definieron los requisitos principales del sistema, priorizando tareas como el desarrollo de un algoritmo de Inteligencia Artificial Explicable (XAI) y la creación de visualizaciones comprensibles. El prototipo inicial del algoritmo de XAI se implementó en Python, utilizando Google Colab para el desarrollo colaborativo y las pruebas. La interfaz se diseñó en paralelo, enfocándose en la usabilidad y la claridad de las explicaciones generadas por el sistema.

### Implementación del Prototipo

El proceso de implementación del prototipo de un sistema de recomendaciones basado en Inteligencia Artificial Explicable (XAI) se llevó a cabo siguiendo una metodología ágil, específicamente Scrum, que permitió desarrollar y refinar el sistema en ciclos iterativos. A continuación se describen las etapas clave del proceso:

#### Planificación Inicial y Creación del Backlog del Producto

#### Actividades Realizadas:

- **Definición de Requisitos:** El equipo identificó las principales características del sistema de recomendación, incluyendo la necesidad de aplicabilidad en las recomendaciones, la integración con datos de licitaciones públicas, y la creación de visualizaciones comprensibles.
- **Priorización de Tareas:** Se establecieron prioridades basadas en la relevancia y el impacto de cada funcionalidad, destacando el desarrollo del algoritmo de XAI, la interfaz de usuario, y las pruebas de precisión y transparencia.

La Figura 1 muestra cómo el sistema de inteligencia artificial explicable se compone del modelo en sí y de una interfaz explicable, mediante la cual el tomador de decisiones interactúa para basar sus decisiones en los resultados proporcionados.




Figura 1. Componentes del Sistema XAI.

**Output:** Se creó una lista priorizada de funcionalidades y tareas, incluyendo el desarrollo del algoritmo de XAI, implementación de visualizaciones y gráficos, y pruebas y validación. La Figura 2 ilustra el backlog del producto desarrollado.




Figura 2. Backlog del Producto.

### Sprint 1: Desarrollo del Algoritmo de XAI

**Objetivo del Sprint:** Desarrollar una primera versión del algoritmo de XAI para el sistema de recomendaciones.

- **Desarrollo del Algoritmo:** El equipo implementó un prototipo básico del algoritmo de XAI utilizando Python en Google Colaboratory.
- **Pruebas Iniciales:** Se realizaron pruebas iniciales para evaluar la precisión y la capacidad de explicación del algoritmo.

**Output:** Algoritmo Prototipo de XAI - Un modelo funcional que proporciona explicaciones básicas para las recomendaciones.

### Sprint 2: Diseño del Sistema de Recomendación

**Objetivo del Sprint:** Crear gráficos interactivos y una interfaz accesible para interactuar con el sistema de recomendaciones, utilizando Google Colab para el desarrollo colaborativo y el procesamiento de datos.

#### Actividades Realizadas:

- Se desarrollaron prototipos iniciales de la interfaz en Google Colab, aprovechando su capacidad para integrar código, visualizaciones y descripciones en un entorno colaborativo.
- Google Colab facilitó la rápida iteración de los diseños, permitiendo a los desarrolladores y diseñadores trabajar simultáneamente en la mejora de los gráficos interactivos y la estructura de la interfaz.
- Se implementaron gráficos interactivos, utilizando bibliotecas como Plotly y Matplotlib, para visualizar los resultados y explicaciones del sistema XAI.

**Pruebas de Usabilidad:** Se realizaron pruebas de usabilidad con usuarios reales, utilizando Google Colab para recopilar y analizar datos de retroalimentación en tiempo real.

**Output:** Diagrama de flujo del sistema de recomendación predictivo usando inteligencia artificial explicable.

### Sprint 3: Integración

**Objetivo del Sprint:** Integrar los datos relacionados con las licitaciones públicas y las empresas de IT participantes, asegurando la correcta funcionalidad del sistema de recomendaciones.

#### Actividades Realizadas:

- Se integraron datos específicos de empresas de IT que participaron en licitaciones públicas, incluyendo información sobre las propuestas presentadas, los contratos adjudicados y el desempeño histórico.
- Los datos fueron recopilados de fuentes como registros oficiales de licitaciones y bases de datos de contratos públicos.
- Se realizó un proceso de limpieza y normalización de los datos para garantizar que toda la información estuviera en un formato consistente y utilizable.

**Pruebas de Funcionamiento:** Se llevaron a cabo pruebas exhaustivas para verificar que el sistema podía manejar correctamente las consultas y recuperar la información relevante de manera eficiente.

**Output:** Base de Datos Integrada y Específica para IT - Los datos estructurados de empresas de IT y sus actividades en licitaciones públicas se integraron exitosamente en el sistema.

### Sprint 4: Implementación de Visualizaciones

**Objetivo del Sprint:** Desarrollar visualizaciones para las explicaciones de las recomendaciones y mejorar el sistema basándose en retroalimentación.

#### Actividades Realizadas:

- **Desarrollo de Visualizaciones:** Se implementaron gráficos y visualizaciones que muestran cómo se generan las recomendaciones.
- **Refinamiento del Algoritmo:** Se ajustó el algoritmo de XAI para mejorar la precisión y la claridad de las explicaciones.
- **Pruebas de Usuario Final:** Se realizaron pruebas con usuarios finales para validar el sistema completo.

**Output:** Sistema de Recomendaciones Completo - Un sistema funcional con visualizaciones que explican las recomendaciones.

### Revisión y Retrospectiva Final

**Objetivo:** Evaluar el proyecto completo, identificar lecciones aprendidas y planificar mejoras futuras.

#### Actividades Realizadas:

- **Revisión del Producto:** Se presentó el sistema final a las partes interesadas, destacando las características implementadas y los resultados obtenidos.
- **Retrospectiva del Proyecto:** Se discutieron los aspectos que funcionaron bien y las áreas de mejora, incluyendo la gestión del tiempo y la comunicación dentro del equipo.

**Output:** Informe de Lecciones Aprendidas - Un documento que recoge las experiencias del proyecto y recomendaciones para futuros desarrollos.

## Machine Learning

El aprendizaje automático, o machine learning, es un campo de la Inteligencia Artificial que se enfoca en crear algoritmos capaces de aprender por sí mismos, sin la necesidad de ser programados de manera detallada para cada situación específica. Esto significa que el desarrollador no necesita programar manualmente cada posible escenario o excepción. En cambio, el algoritmo se entrena alimentándolo con una gran cantidad de datos, permitiéndole adquirir el conocimiento necesario para manejar diferentes casos de forma autónoma.

### Tipos de Aprendizaje de Machine Learning

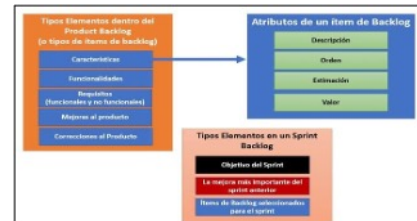
Las diferentes categorías de algoritmos de aprendizaje automático (ML) que se describen a continuación:

- **Aprendizaje supervisado:** En este enfoque, el algoritmo aprende a realizar tareas específicas utilizando un conjunto de datos previamente clasificados. Es decir, se le proporcionan ejemplos con una entrada y una salida conocida, de modo que el algoritmo pueda identificar patrones y aplicarlos en análisis futuros para predecir resultados que ya se conocen.
- **Aprendizaje no supervisado:** A diferencia del aprendizaje supervisado, este tipo de algoritmo trabaja con datos que no están clasificados ni etiquetados. El objetivo es descubrir patrones ocultos o relaciones entre los datos, agrupándolos en función de sus similitudes sin que se le indique al modelo qué buscar específicamente.
- **Aprendizaje por refuerzo:** En este método, el algoritmo no se entrena con datos clasificados o no clasificados, sino que aprende a tomar decisiones a través de la interacción con un entorno. A medida que realiza acciones y observa los resultados, el sistema ajusta su comportamiento para maximizar las recompensas y resolver problemas de manera óptima, reforzando su aprendizaje con la experiencia adquirida.

Estos enfoques de aprendizaje automático ofrecen distintas maneras de entrenar modelos para resolver una amplia variedad de problemas, cada uno adaptándose mejor a diferentes tipos de datos y objetivos.

## Flujograma del Algoritmo Predictivo

El procedimiento del algoritmo predictivo de machine learning se representa en el flujograma mostrado en la Figura 3, comenzando con la generación de datos simulados, los cuales se utilizarán para entrenar y probar el modelo. Inicialmente, se realiza un preprocesamiento exhaustivo de los datos, que incluye la manipulación de valores faltantes, la codificación de variables categóricas y la normalización de las características, asegurando que los datos estén en el formato adecuado para el análisis.



**Figura 3.** Flujograma del algoritmo predictivo de Machine Learning.

A continuación, los datos preprocesados se dividen en conjuntos de entrenamiento y prueba para garantizar que el modelo sea evaluado correctamente. El siguiente paso es entrenar el modelo utilizando un algoritmo de Random Forest, conocido por su eficacia en tareas de clasificación y regresión. Una vez entrenado, el modelo se evalúa para verificar su rendimiento y precisión en la predicción de resultados.

Posteriormente, el modelo entrenado se emplea para comparar proveedores, calculando las probabilidades asociadas a cada uno y generando gráficos comparativos que facilitan la visualización y el análisis de sus fortalezas relativas. El proceso continúa con la visualización de los resultados, permitiendo una interpretación clara y concisa de los datos analizados. Finalmente, se genera una recomendación basada en el análisis comparativo, proporcionando una guía informada sobre la mejor opción disponible.

## Resultados y Discusión

### Análisis de Verificación del Algoritmo

Se optó por la utilización de Google Colab, una herramienta que contiene una colección de paquetes de código abierto para el análisis de datos y que realiza el procesamiento en la nube. Las mediciones tomadas están determinadas en tablas de Excel. Luego a esta data se le realiza un preprocesamiento para asegurarse de que el formato esté correcto. El siguiente paso es explorar los datos de tal manera que, ya con el formato correcto, podemos realizar el preanálisis de los datos para facilitar la construcción del modelo, en donde encontraremos características importantes para realizar la predicción.

Para la fase de entrenamiento, utilizamos las técnicas de machine learning, sustentamos el algoritmo de aprendizaje con los datos que hemos procesado en las anteriores etapas, con la idea de que el algoritmo extraiga los datos útiles para realizar la predicción. Por último, la etapa de evaluar el algoritmo, en la cual ponemos a prueba el conocimiento del algoritmo luego del entrenamiento,

evaluamos la precisión del algoritmo en las predicciones observando minuciosamente el rendimiento del mismo.

A continuación, se detallará cada uno de los pasos a seguir para el funcionamiento del sistema predictivo:

**1. Importación de Bibliotecas.** En esta sección, se importan bibliotecas cruciales para el análisis de datos y la creación del modelo de Machine Learning:

- **Pandas y Numpy:** Para la manipulación y análisis de datos.
- **Scikit-Learn:** Para herramientas de Machine Learning, incluyendo la separación de datos (train\_test\_split), escalado (StandardScaler), clasificación (RandomForestClassifier), y evaluación (accuracy\_score, classification\_report, confusion\_matrix).
- **Matplotlib y Seaborn:** Para la visualización de datos.

La Figura 4 muestra el código de importación de bibliotecas.

```
import pandas as pd
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import accuracy_score, classification_report, confusion_matrix
from sklearn.impute import SimpleImputer
import matplotlib.pyplot as plt
import seaborn as sns
```

Figura 4. Importación de bibliotecas para el análisis de datos.

En esta sección, se procede a configurar Matplotlib, el cual nos muestra la salida directa de cualquier gráfico que se proceda a programar. El comando `plt.style.use(seaborn)` configura Matplotlib para utilizar el estilo de gráficos “seaborn”, biblioteca de visualizaciones de datos.

**2. Función de Ingreso de Datos.** Este bloque define una función llamada `ingresar_datos_proveedor()` que solicita al usuario ingresar diversos datos relacionados con un proveedor:

- Nombre del proveedor
- Años de experiencia
- Número de proyectos completados
- Tiempo de respuesta promedio (horas)
- Costo por hora (\$)
- Satisfacción del cliente (1-5)
- Número de certificaciones
- Número de personal calificado
- Cobertura nacional (0-No, 1-Sí)
- Soporte 24/7 (0-No, 1-Sí)
- Especialización en sector público (0-1)
- Cumplimiento de SLA (0.7-1)
- Resumen de la propuesta técnica

- Resumen de experiencia previa relevante

Las Figuras 5 y 6 muestran el código de captura de datos del proveedor.

```
def ingresar_datos_proveedor():
    proveedor = proveedor
    experiencia_anos = experiencia_anos
    proyectos_completados = proyectos_completados
    tiempo_respuesta_horas = tiempo_respuesta_horas
    costo_por_hora = costo_por_hora
    satisfaccion_cliente = satisfaccion_cliente
    certificaciones = certificaciones
    personal_calificado = personal_calificado
    cobertura_nacional = cobertura_nacional
    soporte_24_7 = soporte_24_7
    especializacion_sector_publico = especializacion_sector_publico
    cumplimiento_sla = cumplimiento_sla
    propuesta_tecnica = propuesta_tecnica
    experiencia_previa = experiencia_previa
```

Figura 5. Función de ingreso de datos del proveedor - Parte 1.

```
def ingresar_datos_proveedor():
    # Datos de contacto y general
    proveedor = proveedor
    experiencia_anos = experiencia_anos
    proyectos_completados = proyectos_completados
    tiempo_respuesta_horas = tiempo_respuesta_horas
    costo_por_hora = costo_por_hora
    satisfaccion_cliente = satisfaccion_cliente
    certificaciones = certificaciones
    personal_calificado = personal_calificado
    cobertura_nacional = cobertura_nacional
    soporte_24_7 = soporte_24_7
    especializacion_sector_publico = especializacion_sector_publico
    cumplimiento_sla = cumplimiento_sla
    propuesta_tecnica = propuesta_tecnica
    experiencia_previa = experiencia_previa
```

Figura 6. Función de ingreso de datos del proveedor - Parte 2.

**3. Organización de Datos.** Este bloque de código organiza toda la información capturada sobre un proveedor en un diccionario, permitiendo que todos estos datos sean retornados como una unidad cohesiva. El uso de un diccionario facilita el acceso y la manipulación de los datos en otras partes del programa, proporcionando una estructura clara y accesible para la evaluación de proveedores. La Figura 7 ilustra esta estructura.

```
def ingresar_datos_proveedor():
    # Datos de contacto y general
    proveedor = proveedor
    experiencia_anos = experiencia_anos
    proyectos_completados = proyectos_completados
    tiempo_respuesta_horas = tiempo_respuesta_horas
    costo_por_hora = costo_por_hora
    satisfaccion_cliente = satisfaccion_cliente
    certificaciones = certificaciones
    personal_calificado = personal_calificado
    cobertura_nacional = cobertura_nacional
    soporte_24_7 = soporte_24_7
    especializacion_sector_publico = especializacion_sector_publico
    cumplimiento_sla = cumplimiento_sla
    propuesta_tecnica = propuesta_tecnica
    experiencia_previa = experiencia_previa
```

Figura 7. Organización de datos en estructura de diccionario.

**4. Generación de Datos Simulados.** Este fragmento de código está diseñado para generar un conjunto de datos simulados que imitan la participación de proveedores tecnológicos en procesos de licitación. Las listas de proveedores, propuestas técnicas y experiencias previas proporcionan la base para la creación de datos diversos y realistas, esenciales para la evaluación y comparación en estudios de caso o pruebas de modelos. Con esta función, se pueden generar rápidamente grandes volúmenes de datos que faciliten el análisis en un entorno controlado.

**5. Funciones de Explicación.** Este bloque declara las funciones útiles para generar automáticamente explicaciones detalladas y contextualizadas sobre las características, propuestas técnicas y experiencias previas de un proveedor, especialmente en el análisis de datos de licitaciones.

**6. Comparación de Proveedores.** El siguiente fragmento, mostrado en la Figura 8, tiene como objetivo comparar diversos proveedores de servicios basándose en ciertos criterios. Aquí se realizan verificaciones básicas de entrada, la extracción de datos específicos para cada proveedor seleccionado, y la preparación de estructuras de datos para realizar la comparación.



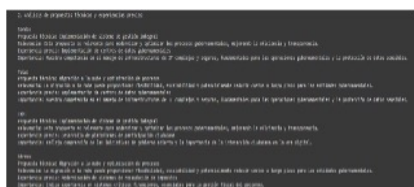


Figura 16. Resumen gráfico de probabilidades de selección.



Figura 17. Análisis de propuestas técnicas de proveedores.

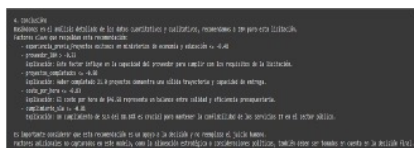


Figura 18. Interpretación de datos mediante gráficos.

## Conclusiones

Las principales conclusiones del proyecto son las siguientes:

- Se implementaron algoritmos de aprendizaje supervisado y no supervisado para generar recomendaciones precisas. La interfaz fue diseñada para ser intuitiva y fácil de usar, lo que facilitó la interacción del usuario con el sistema.
- La mayoría de los usuarios encontraron que las recomendaciones eran precisas y útiles, y la interfaz fue calificada como clara y bien diseñada. Los usuarios también reportaron una alta satisfacción con la capacidad del sistema para reducir costos.
- Los resultados obtenidos cumplen con los objetivos iniciales de proporcionar un sistema de recomendación efectivo y explicable que pueda ayudar a minimizar el gasto público en desarrollo.
- El sistema de XAI desarrollado ha demostrado ser efectivo en proporcionar explicaciones claras y comprensibles de las recomendaciones, lo que ha incrementado significativamente la confianza de los usuarios en el proceso de toma de decisiones automatizada.
- La implementación del sistema ha contribuido a optimizar los procesos de licitación pública, reduciendo el tiempo necesario para evaluar proveedores y mejorando la calidad de las decisiones tomadas.
- El enfoque metodológico utilizado y las herramientas implementadas pueden ser adaptadas y escaladas para su aplicación en otros contextos de contratación pública y sectores relacionados.

## Agradecimientos

Se agradece de manera especial a las personas e instituciones que han colaborado en el desarrollo de este proyecto, en particular a la Universidad de Guayaquil por el apoyo brindado, y al Servicio Nacional de Contratación Pública (SERCOP) por facilitar el acceso a información relevante para la investigación.

## Referencias

- Alcarazo, L. O. (2022). Evaluación de modelos de inteligencia artificial explicable. *Universidad Autónoma de Madrid*.
- Couñago, P. (2021). Sistemas de recomendación basado en contenido.
- Fonseca, B. and Cornelio, A. (2022). Sistemas de recomendación híbridos.
- Fonseca, B. B. (2021). Sistemas de recomendación.
- Gonzalo, A. M. (2022). Evaluación de modelos de inteligencia artificial explicable. caso de uso con clasificadores de licitaciones públicas a partir de textos. Master's thesis, Universidad Politécnica de Madrid.
- Hernández, N. B. (2020). Transparencia y equidad en las recomendaciones basadas en ia en procesos de licitación pública.
- Janiesch, C., Zschech, P., and Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31:685–695.
- Mimbrera, E. (2021). Inteligencia artificial explicable.
- Pathak, S. (2024). La xai - explainable artificial intelligence.
- Rojo, P. (2019). Modelo predictivo de análisis de riesgo crediticio usando machine learning en una entidad del sector microfinanciero. Master's thesis.
- Valenzuela, J., Correa, C., and Rendon, D. (2022). Sistemas de recomendación basado en filtrados colaborativos.