

Análisis de licitaciones públicas en Ecuador: aplicación de técnicas de explicabilidad en modelos de aprendizaje automático

Analysis of Public Tenders in Ecuador: Application of Explainability Techniques in Machine Learning Models

Fecha de recepción: 2024-12-09 • Fecha de aceptación: 2025-01-07 • Fecha de publicación: 2025-02-10

María Fernanda Molina Miranda¹

Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Físicas, Ecuador

maria.molinam@ug.edu.ec

Universidad de Granada, España

molinamafer@correo.ugr.es

<https://orcid.org/0000-0002-4237-4364>

Ángel Cuenca Ortega²

Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Físicas, Ecuador

angel.cuencao@ug.edu.ec

<https://orcid.org/0000-0001-7798-611X>

Luis Espín Pazmiño³

Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Físicas, Ecuador

lespinp@ug.edu.ec

<https://orcid.org/0000-0002-1663-2489>

Miguel Molina Villacís⁴

miguel.molinav@ug.edu.ec

Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Físicas, Ecuador

<https://orcid.org/0000-0002-7080-2354>

RESUMEN

Las licitaciones públicas permiten a las instituciones contratar bienes, obras y servicios esenciales para el crecimiento del país. Este trabajo consistió en analizar los procesos de licitaciones públicas en Ecuador mediante la aplicación de técnicas de aprendizaje automático y explicabilidad de modelos, con el fin de mejorar la toma de decisiones. Se recopiló y procesó un conjunto de datos abiertos extraídos de la base de datos del SERCOP para identificar patrones y variables clave que influyeron en el éxito de las licitaciones. Utilizando modelos de clasificación como Random Forest, AdaBoost y CatBoost, y técnicas de explicabilidad como SHAP y Feature Importance, se desarrollaron modelos predictivos que permiten comprender de manera transparente las decisiones generadas por los algoritmos. Los resultados mostraron que CatBoost fue el modelo con mayor precisión predictiva y Feature Importance resultó ser la técnica más efectiva para explicar las predicciones. Además, se procedió a crear una interfaz web que permitió ingresar los datos de entrada y determinar si es recomendable que una empresa participe en una licitación. La inteligencia artificial explicable no solo mejora la precisión, sino que también proporciona información valiosa para que las empresas optimicen su participación en estos procesos.

PALABRAS CLAVE: licitaciones, toma de decisiones, algoritmos, SHAP, feature importance

ABSTRACT

Public tenders allow institutions to contract goods, works, and services essential for the country's growth. This work consists of analyzing public tender processes in Ecuador through the application of machine learning techniques and model explainability to improve decision-making. An open dataset extracted from the SERCOP database was collected and processed to identify patterns and key variables that influence the success of tenders. Using classification models such as Random Forest, AdaBoost, and CatBoost, along with explainability techniques like SHAP and Feature Importance, predictive models were developed to transparently understand the decisions generated by the algorithms. The results show that CatBoost was the model with the highest predictive accuracy, and Feature Importance proved to be the most effective technique for explaining the predictions. Furthermore, a web interface was created to input data and determine whether it is advisable for a company to participate in a tender. Explainable artificial intelligence not only improves accuracy but also provides valuable insights for companies to optimize their participation in these processes.

KEYWORDS: tenders, decisión making, algorithms, SHAP, feature importance

Introducción

Las licitaciones públicas juegan un papel esencial en el desarrollo económico de los países, ya que permiten a las instituciones acceder a los bienes, servicios y obras necesarias para su funcionamiento. En Ecuador, este proceso constituye un mecanismo clave para fomentar la competencia y garantizar la transparencia en la asignación de contratos. Sin embargo, a pesar de la importancia de las licitaciones, muchas empresas enfrentan dificultades al decidir si participar en estos procesos, debido a la falta de herramientas predictivas que les permitan evaluar sus probabilidades de éxito. (Sisa Garcés, 2022)

Con el avance de la inteligencia artificial y el aprendizaje automático, han surgido nuevas oportunidades para analizar grandes volúmenes de datos y ofrecer modelos capaces de identificar patrones y variables que influyen en los resultados de las licitaciones. Este estudio buscó aprovechar esas tecnologías integrando técnicas de explicabilidad de modelos para proporcionar una visión clara y comprensible de las decisiones generadas por los algoritmos predictivos. En particular, el uso de modelos explicables no solo mejora la precisión de las predicciones, sino que también permite a las empresas tomar decisiones informadas sobre su participación en licitaciones.

A través de la recopilación de datos abiertos del Servicio Nacional de Contratación Pública (SERCOP), este trabajo presentó un análisis detallado del comportamiento de las licitaciones públicas en Ecuador, desarrollando además una interfaz web que permitió a las empresas ingresar sus datos y recibir recomendaciones sobre su participación. De esta forma, se buscó contribuir al campo de la contratación pública mediante la creación de una herramienta que optimiza la toma de decisiones estratégicas, brindando a las empresas una ventaja competitiva basada en datos.

1.1 Trabajos relacionados

En los últimos años, la inteligencia artificial ha sido ampliamente adoptada en diferentes áreas (Guida et al., 2023), y su rápido crecimiento en el uso de las técnicas de aprendizaje automático está transformando los procesos de toma de decisiones, mejorando su eficiencia a través del análisis de grandes volúmenes de datos generados por estos mismos procesos (Salem et al., 2024; Riyad y Laila, 2024).

En el ámbito de la contratación pública, estudios recientes han analizado conjuntos de datos relacionados con procesos de licitación, entrenando modelos de aprendizaje automático para identificar las características más influyentes en la clasificación de propuestas (Nai et al., 2023). El aprendizaje automático se ha consolidado como uno de los enfoques analíticos más importantes para el análisis de datos y el reconocimiento de patrones (Arena et al., 2024). Aunque los algoritmos suelen requerir grandes cantidades de información, las herramientas disponibles son flexibles incluso con cantidades limitadas de datos (García et al., 2022).

Además, autores como Rosales et al. (2024) destacaron que el análisis avanzado de datos no solo permite una mejor interpretación y presentación de la información, sino que puede resolver situaciones por sí solo a partir del análisis. Además, con la utilización de algoritmos de machine

learning ya que estos requieren mucha información generando modelos de predicción (Rojas, 2020; García et al., 2022).

Otra investigación relevante propuso un modelo inteligente para ayudar a los postores a aumentar sus posibilidades de éxito, clasificando su elegibilidad mediante algoritmos como KNN, SVM y Random Forest (Oussaleh y Azmani, 2023). Este enfoque es consistente con el uso de algoritmos de clasificación como Árboles de Decisión, Regresión Logística y Random Forest, para predecir la viabilidad de que las pequeñas y medianas empresas (PYMES) participen en compras públicas (Molina et al., 2023).

La inteligencia artificial explicable (XAI) desempeña un papel clave en este contexto, ya que permite aclarar cómo los modelos de IA llegan a sus resultados, respondiendo a preguntas clave sobre el proceso y ayudando a los usuarios a comprender, confiar y mejorar la toma de decisiones. Esto es fundamental en sectores como la contratación pública, donde la transparencia y la confianza son esenciales (Gohel et al., 2021; Love et al, 2023).

Finalmente, los sistemas de recomendación basados en técnicas de Machine Learning también se han destacado como herramientas eficaces para mejorar la precisión en las recomendaciones, permitiendo a las empresas y organismos optimizar su alcance y servicios, y evaluando métricas clave para asegurar el éxito de las técnicas aplicadas (Pita, 2021; Anwar y Siddiqui, 2020).

Metodología

En el presente trabajo investigativo se implementó la metodología investigativa cuantitativa y la metodología CRISP-DM, la cual consta de las siguientes fases.

2.1 Comprensión del negocio

El proceso de licitación pública en Ecuador es fundamental para gestionar el uso de los recursos públicos y la ejecución de proyectos que son beneficios para la población ecuatoriana. El propósito de esta investigación ha sido mejorar la toma de decisiones en un proceso licitatorio, enfocándonos en los patrones para la selección de los ganadores. Se identificaron los factores que influyen en la adjudicación de los contratos para proporcionar herramientas y modelos explicativos que ayuden a las empresas a tomar mejores decisiones sobre su participación de las licitaciones públicas y así mejorar sus oportunidades. Además, se probaron modelos de inteligencia artificial explicable que nos indicaron qué factores son determinantes para la elección de un ganador usando datos históricos de las licitaciones públicas que incluyó información detallada de cada etapa de los procesos licitatorios.

2.2 Comprensión de los datos

Los datos con los que se trabajó en esta investigación fueron obtenidos de la plataforma de Servicio Nacional de Contrataciones Públicas de datos abiertos de Ecuador. Los datos extraídos abarcan entre los años 2022 a 2024 siendo un total de 2784 registros y 79 características donde se

pudo identificar que existen 57 atributos de tipo texto, 2 atributos de tipo numérico y 20 atributos de tipo decimal.

La información descargada en formato xlsx está compuesta por 6 hojas. A continuación, se detalla cada hoja:

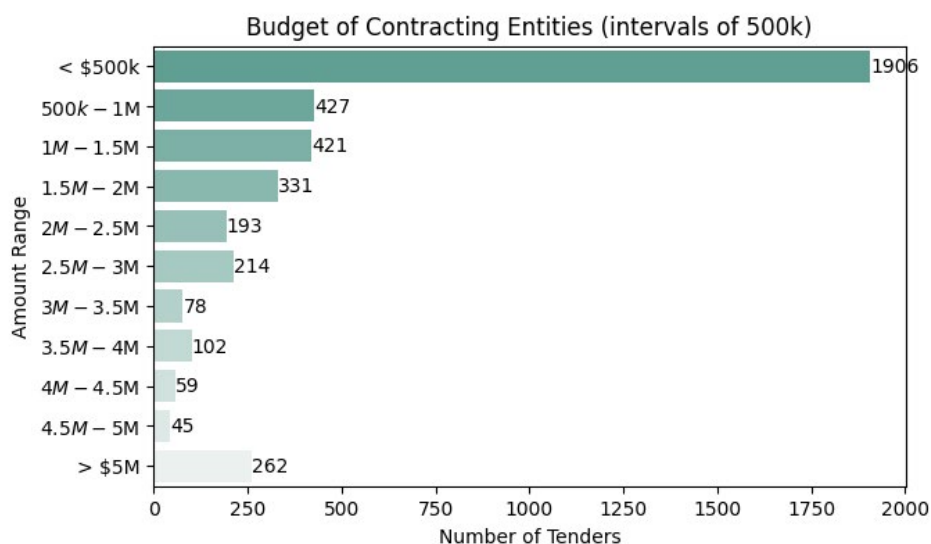
- Releases: Información general del proceso de licitación.
- Planning: Detalles sobre la planificación de la licitación.
- Tender: Información detallada sobre la licitación, como métodos de adquisición y periodos.
- Awards: Detalles de las adjudicaciones.
- Award Suppliers: Información sobre los proveedores adjudicados.
- Contracts: Información sobre los contratos firmados.

Una vez extraído el conjunto de datos, agrupamos las hojas de Excel en un mismo DataFrame mediante el identificador del procedimiento de contratación para tener una mejor comprensión de los datos y una mejor vista de todas las etapas del proceso de licitación en un mismo conjunto de datos. Posteriormente, se procedió a la recopilación manual de los presupuestos y la información de los oferentes que participaron en las licitaciones tanto de aquellos que resultaron adjudicados como los que no lograron la adjudicación.

La *Figura 1* muestra el presupuesto que han ofertado las entidades contratantes en las licitaciones. Se puede observar cómo se distribuyeron los presupuestos asignados en las licitaciones, en donde la mayoría de las licitaciones se adjudicaron a proyectos que requirieron presupuestos bajos.

Figura 1


Presupuesto de las Empresas Contratantes.



La *Figura 2* indicó cómo existe un mayor número de licitaciones en la categoría de servicios, lo que nos indica que es la categoría más solicitada en licitaciones.

Figura 2


Categorías de las Licitaciones.



La *Figura 3* mostró el número de oferentes por licitación reflejando que el número de licitaciones disminuye a medida que aumenta el número de ofertantes, siendo menos comunes las licitaciones con muchos ofertantes.

Figura 3

Oferentes por Licitación.



2.3. Preparación de los datos

A partir de la exploración del conjunto de datos se evidenció que la mayoría de los atributos son textuales, lo cual implica que no se pueden emplear directamente en el entrenamiento del

modelo. Esto se debe a que los algoritmos de aprendizaje automático requieren valores numéricos o categóricos que puedan procesarse de manera eficiente. La *Tabla 1* presentó las columnas relevantes que se eligieron resultado de las necesidades para esta investigación.

Tabla 1

Características Importantes.

Nombre	Descripción	Tipo de dato
budget_amount	Presupuesto de la licitación	Real
Amount	Monto ofertado	Real
Ganador	Indica si gana la licitación	Texto
mainProcurementCategory	Categoría de la licitación	Texto
numberOfTenderers	Número de licitadores	Entero
contractPeriod_durationInDays	Duración en días del contrato	Real
tenderPeriod_durationInDays	Duración del período de licitación en días	Real
eligibilityCriteria	Criterios de elegibilidad	Texto

2.3.1. Transformación y Codificación de Variables.

Se realizó la imputación de valores nulos en la columna Duración del Contrato utilizando la mediana. Además, se eliminaron los registros con valores vacíos en cualquiera de las columnas, dejando únicamente los datos completos recolectados de la página del SERCOP.

```
# Impute missing values with the median
df=df.fillna({'contractPeriod_durationInDays':df['contractPeriod_durationInDays'].
median()})
# Drop rows with NaN values in any column
df = df.dropna()
```

Los resultados muestran que ninguna columna tiene celdas vacías, y el número final de registros es 2536.

```
# Check for empty cells by column
empty_cells = df.isnull().sum()
print(empty_cells)
# Get the number of records
record_count = df.shape[0]
print ("Number of records:", record_count)
```

```
budget_amount 0
```

```

mainProcurementCategory      0
tenderPeriod_durationInDays  0
numberOfTenderers            0
amount                       0
contractPeriod_durationInDays 0
ganador                       0
eligibilityCriteria          0
dtype: int64
Number of records: 2536

```

Además, se aplicó el codificador LabelEncoder para convertir las variables categóricas en valores numéricos. Las variables seleccionadas para esta codificación fueron mainProcurementCategory y ganador.

2.3.2. Análisis de Frecuencia de Criterios de Elegibilidad.

Los criterios de elegibilidad presentaban una gran variedad de valores textuales. Para estandarizar esta variable, se seleccionaron criterios clave y se transformaron en variables binarias, lo cual permitió identificar su impacto en el modelo.

```

# Define the specific parameters
specific_parameters = [
    'Oferta Económica',
    'Experiencia Específica',
    'Experiencia General',
    'Experiencia Personal Técnico',
    'Otros',
    'Participación Ecuatoriana',
    'VAE']
# Create binary columns for each specific criterion
for criterion in specific_parameters:
    df[criterion] = df['eligibilityCriteria'].apply(lambda x: 1 if criterion
in x else 0)

```

2.3.3. Eliminación de Outliers.

Se utilizó el modelo Isolation Forest para detectar y eliminar valores atípicos en el conjunto de datos, lo cual mejoró la calidad de las predicciones del modelo. Finalmente, se muestra la cantidad de registros que permanecen después de eliminar los valores atípicos, que es de 2485.

```

import pandas as pd
from sklearn.ensemble import IsolationForest
from sklearn.preprocessing import StandardScaler
# Create the Isolation Forest model
iso_forest = IsolationForest(contamination=0.02, random state=2021)
# Fit the model

```



```
iso_forest.fit(df)
# Make predictions
y_pred = iso_forest.predict(df)
# Filter outliers
df = df[y_pred == 1]
# Show the number of records after removing outliers
print("Number of records:", df.shape[0])
```

2.3.4. Distribución de la clase Ganador.

La *Figura 4* muestra la distribución de la variable “Ganador”, que evidenció un ligero desbalance hacia las licitaciones perdedoras. Este sesgo podría influir en el desempeño del modelo.

Figura 4

Distribución de la Clase “Ganador”.



2.4 Modelado

En esta fase se seleccionaron los siguientes algoritmos de clasificación:

- **CatBoost.** Es un algoritmo de aprendizaje automático basado en potenciación del gradiente, funciona perfectamente con múltiples categorías de datos, además el algoritmo se basa en la técnica de “Gradient boosting” (potenciación del gradiente). La potenciación del gradiente es una técnica que se aplica en múltiples tipos de problemas como la detección como motores de recomendaciones y predicciones.
- **AdaBoost.** Entrena de forma secuencial un conjunto de aprendices débiles a partir de un algoritmo base común. Todos los aprendices son entrenados con el mismo conjunto de datos, pero éstos van recibiendo pesos que dependen de los errores cometidos por cada aprendiz.
- **Random Forest.** Es un algoritmo de aprendizaje supervisado utilizado tanto en tareas de clasificación como de regresión. Este método puede manejar variables continuas y

categorías, ofreciendo resultados precisos y robustos. Su funcionamiento se basa en la construcción de múltiples árboles de decisión durante el proceso de entrenamiento, lo que permite mejorar la precisión.


Para realizar el modelado se seleccionaron las características más importantes como variables de entrada que son número de oferentes, categoría principal, presupuesto, monto ofertado, duración licitación días y duración contrato días y como variables de salida ganador. Luego, el conjunto de datos se dividió en 70% para entrenamiento y un 30% para prueba y evaluación del modelo.

2.5 Evaluación

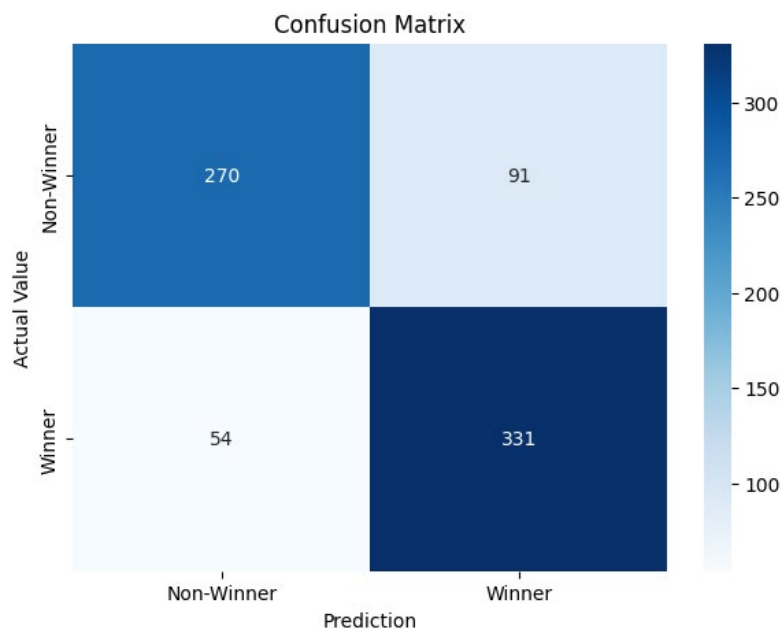
Para evaluar los modelos entrenados se graficó las curvas ROC y se calculó el AUC para los tres modelos de clasificación. En la *Figura 5* se comparó el desempeño de tres modelos de clasificación: CatBoost, AdaBoost, y Random Forest. El modelo CatBoost fue el más efectivo, con un AUC de 0.80, seguido de AdaBoost con un AUC de 0.78, y finalmente Random Forest con un AUC de 0.67 y vemos que la curva ROC de CatBoost fue la que más se acercó a 1. Esto indicó que CatBoost tuvo la mejor capacidad para distinguir entre las clases en este conjunto de datos, mientras que Random Forest fue el menos preciso.

Figura 5

Curva ROC de los Modelos.



En la *Figura 6* se visualizó la matriz de confusión de CatBoost, que mostró el desempeño del modelo de clasificación en predecir si una oferta es ganadora o no ganadora. El modelo predijo correctamente un “ganador” en 331 ocasiones y un “no ganador” en 270 ocasiones. Sin embargo, hubo 91 casos donde predijo incorrectamente una licitación ganadora y 54 casos donde predijo incorrectamente licitaciones no ganadoras. Esto indicó un buen desempeño general, pero con considerables errores.

Figura 6*Matriz de Confusión.*

Para implementar técnicas de inteligencia artificial explicable, se seleccionaron dos métodos: SHAP y Feature Importance.

La técnica de importancia de características permitió identificar cuáles atributos fueron más relevantes para las decisiones del modelo. La *Figura 7* ilustró esta relevancia, destacando que la característica más influyente fue NumeroOferentes, seguida por MontoOfertado, Presupuesto, DuracionLicitacionDias, CategoriaPrincipal y DuracionContratoDias es la característica menos significativa.

La técnica SHAP proporcionó interpretaciones globales. La *Figura 8* mostró un Summary plot de los valores SHAP, el eje x muestra el impacto de cada característica en la predicción del modelo, con valores positivos aumentando y valores negativos disminuyendo la predicción. El eje y enumera las características del modelo y los colores indican los valores de estas características, donde el azul representa valores bajos y el rosa y rojo valores altos. Características como NumeroOferentes y MontoOfertado son las más influyentes, con valores altos de ambas tendiendo a aumentar la predicción del modelo, mientras que valores bajos tienden a reducirla. CategoriaPrincipal, Presupuesto, DuracionLicitacionDias, y DuracionContratoDias tienen un impacto más moderado y variable. El código fuente está disponible en <https://bit.ly/3TMakNN>.

Figura 7

Técnica Feature Importance.

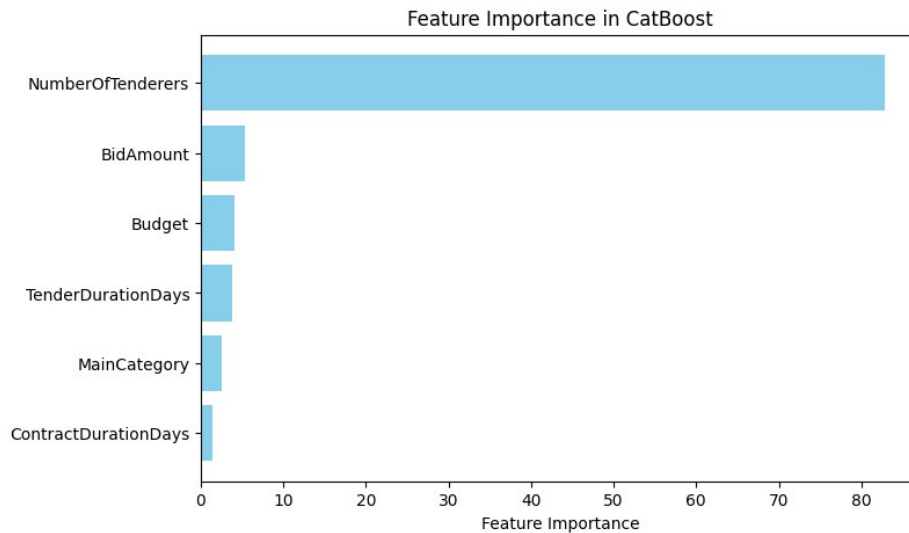



Figura 8

Técnica SHAP

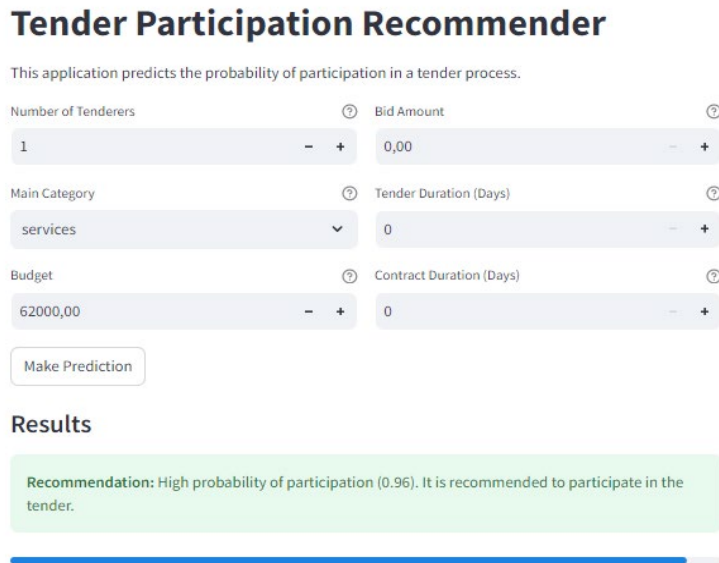


2.6 Despliegue

Para el despliegue, se utilizó la biblioteca de Python Streamlit. Esta herramienta facilitó la creación de interfaces de usuario de manera sencilla y accesible. Una vez desplegado el modelo, la página muestra un prototipo denominado “Recomendador de Participación en Licitaciones”. Este prototipo permite al usuario ingresar diversos parámetros del proceso licitatorio incluyendo el número de oferentes, el monto ofertado, la categoría principal, el presupuesto, la duración de la licitación y la duración del contrato. Después de ingresar los datos y hacer clic en “Hacer Predicción”, la aplicación calcula y presenta una recomendación basada en la probabilidad de participación.

Figura 9

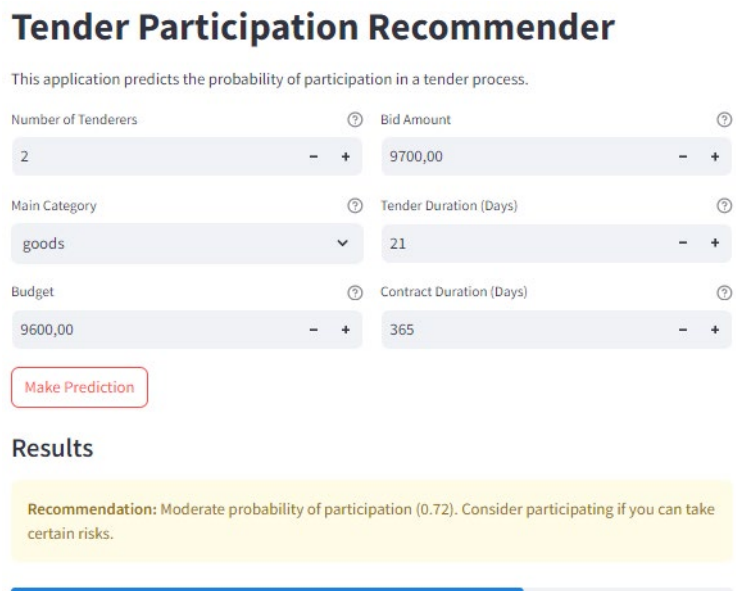
Probabilidad Alta.



En la *Figura 9* se observó una alta probabilidad de éxito (0.96), lo que sugiere que es recomendable participar en la licitación.

Figura 10

Probabilidad Moderada.



En contraste, la *Figura 10* mostró una probabilidad moderada (0.72), mientras que la *Figura 11* indica una probabilidad baja (0.48), lo que podría implicar un menor incentivo para participar. En estos tres casos se pudo observar que entre menor es el número de oferentes hay una mayor probabilidad de participación. El código fuente del despliegue se encuentra disponible en <https://bit.ly/3ZD6ll6>.

Figura 11

Probabilidad Baja.

Tender Participation Recommender

This application predicts the probability of participation in a tender process.

Number of Tenderers	?	Bid Amount	?
3	- +	60000,00	- +
Main Category	?	Tender Duration (Days)	?
services	▼	30	- +
Budget	?	Contract Duration (Days)	?
62000,00	- +	625	- +

Make Prediction

Results

Recommendation: Low probability of participation (0.48). It is recommended not to participate in the tender.

Resultados

Los resultados de este estudio destacaron la importancia de utilizar técnicas de aprendizaje automático y explicabilidad en las licitaciones públicas en Ecuador. El modelo CatBoost, con su alta precisión y capacidad de interpretación, proporcionaron a las empresas información clave para tomar decisiones fundamentadas sobre su participación en estos procesos.

La técnica de importancia de características ha identificado factores críticos, como el número de oferentes y el monto ofertado, que influyen en el éxito de las licitaciones. Esto permite a las empresas enfocar sus esfuerzos en áreas que aumentan sus probabilidades de ganar.

La implementación de inteligencia artificial explicable (XAI) facilitó la comprensión de las decisiones del modelo, fomentando la confianza entre los usuarios. Además, la creación de una interfaz web accesible democratiza la información, permitiendo a las empresas recibir recomendaciones personalizadas y mejorar su eficiencia en la participación.

En resumen, este estudio no solo contribuyó al análisis de las licitaciones públicas mediante el uso de modelos predictivos, sino que también resaltó la importancia de la transparencia y la explicabilidad en la toma de decisiones.

Conclusiones

En este trabajo se analizó el comportamiento de las empresas en licitaciones públicas en Ecuador mediante técnicas de machine learning y explicabilidad. A partir de 2,536 datos históricos obtenidos de la plataforma de datos abiertos de contratación pública, se aseguró la calidad y coherencia de la información, lo que facilitó su análisis.

La exploración de datos reveló importantes tendencias y patrones destacando variables clave como la categoría de las empresas y el monto ofertado, que mostraron correlaciones significativas con la participación en las licitaciones. Este análisis permitió comprender mejor los factores que influyen en los resultados de las licitaciones.

Además, se implementaron técnicas de explicabilidad que proporcionaron un entendimiento más profundo del funcionamiento de los modelos predictivos. El algoritmo CatBoost se destacó al ofrecer una precisión del 80%. Estas técnicas no solo facilitaron el desglose de cómo las características afectan las predicciones, sino que también ayudaron a identificar los factores más determinantes en el éxito de las ofertas.

Expresamos nuestro más sincero agradecimiento a las estudiantes Gilda Jamileth Pincay Baque y Nicole Isabel Velásquez Arroyo por su valiosa colaboración en el proyecto FCI-046-2023, titulado *'Modelo de predicción para la mejora de la toma de decisiones en sistemas de recomendación de licitaciones públicas mediante técnicas de inteligencia artificial explicables'*. Su dedicación y compromiso fueron fundamentales para el desarrollo de esta investigación.



Referencias

- Anwar, K., Siddiqui, J., y Saquib, S. (2020). Machine learning-based book recommender system: a survey and new perspectives. *International Journal of Intelligent Information and Database Systems*, 13(2-4), 231-248. <https://doi.org/10.1504/IJIDS.2020.109457>
- Arena, S., Florian, E., Sgarbossa, F., Sølvsberg, E., y Zennaro, I. (2024). A conceptual framework for machine learning algorithm selection for predictive maintenance. *Engineering Applications of Artificial Intelligence*, 133. <https://doi.org/10.1016/j.engappai.2024.108340>
- García, M., Rodríguez, V., Ballesteros, P., Love, P., y Signor, R. (2022). Collusion detection in public procurement auctions with machine learning algorithms. *Automation in Construction*, 133. <https://doi.org/10.1016/j.autcon.2021.104047>
- Gohel, P., Singh, P., y Mohanty, M. (2021). Explainable AI: current status and future directions. *Arxiv*. <https://doi.org/10.48550/arXiv.2107.07045>
- Guida, M., Caniato, F., Moretto, A., y Ronchi, S. (2023). The role of artificial intelligence in the procurement process: State of the art and research agenda. *Journal of Purchasing and Supply Management*, 29(2). <https://doi.org/10.1016/j.pursup.2023.100823>
- Love, P., Fang, W., Matthews, J., Porter, S., Luo, H., y Ding, L. (2023). Explainable artificial intelligence (XAI): Precepts, models, and opportunities for research in construction. *Advanced Engineering Informatics*, 57. <https://doi.org/10.1016/j.aei.2023.102024>
- Molina, M., Acaro, X., Molina, M., Quinoñez, M., Alvarez, G., y Fernandez, J. (2023). Application of explainable artificial intelligence to analyze basic features of a tender. *Actas de International Conference on Electrical, Computer, Communications and Mechatronics Engineering, ICECCME 2023* (pp. 1-6). España. 10.1109/ICECCME57830.2023.10253063
- Nai, R., Meo, R., Morina, G., y Pasteris, P. (2023). Public tenders, complaints, machine learning and recommender systems: a case study in public administration. *Computer Law & Security Review*, 51. <https://doi.org/10.1016/j.clsr.2023.105887>
- Oussaleh, A. y Azmani, A. (2023). Smart Sourcing Framework for Public Procurement Announcements Using Machine Learning Models. *International Conference on Advanced Intelligent Systems for Sustainable Development*, 637, 921-932. https://doi.org/10.1007/978-3-031-26384-2_83
- Pita, C. (2021). Proyecto de Sistema de Recomendación de Filtrado Colaborativo basado en Machine Learning. *Revista PGI*(8), 48-51. https://ojs.umsa.bo/ojs/index.php/inf_fcpn_pgi/article/view/46

- Riyad, B. y Laila, E. (2024). The Artificial Intelligence and Public Procurement. *Actas de 2024 IEEE 15th International Colloquium of Logistics and Supply Chain Management (LOGISTIQUA)*, (pp. 1-6). Tunisia. 10.1109/LOGISTIQUA61063.2024.10571429
- Rojas, E. (2020). Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo. *Revista Ibérica de Sistemas e Tecnologias de Informação*,(28), 586-599. <https://www.proquest.com/openview/c7e24c997199215aa26a39107dd2fe98/1?pq-origsite=gscholar&cbl=1006393>
- Rosales, C., Mango, P., Turpo, O., Miranda, V., y Aranda, Á. (2024). El análisis exploratorio de datos: una oportunidad para desarrollar competencias STEM/STEAM. *Revista Ibérica de Sistemas e Tecnologias de Informação*, (70), 87-104. <https://dialnet.unirioja.es/servlet/articulo?codigo=9886356>
- Salem, A., Eyupoglu, S., y Ma'aitah, M. (2024). The Influence of Machine Learning on Enhancing Rational Decision-Making and Trust Levels in e-Government. *Systems*, 12(9). <https://doi.org/10.3390/systems12090373>
- Sisa, G. (2022). *Propuestas para mejorar la contratación e inclusión de las pequeñas y medianas empresas en el sistema de contratación pública del Ecuador* [Tesis de posgrado, Universidad Andina Simón Bolívar]. Repositorio Institucional. <https://repositorio.uasb.edu.ec/bitstream/10644/8550/1/T3734-MDACP-Sisa-Propuestas.pdf#page=53.20>

Copyright (2025) © Maria Fernanda Molina-Miranda; Angel Cuenca-Ortega; Luis Espín-Pazmiño; Miguel Molina Villacís



Este texto está protegido bajo una licencia internacional [Creative Commons](#) 4.0.

Usted es libre para Compartir—copiar y redistribuir el material en cualquier medio o formato — y Adaptar el documento — remezclar, transformar y crear a partir del material—para cualquier propósito, incluso para fines comerciales, siempre que cumpla las condiciones de Atribución. Usted debe dar crédito a la obra original de manera adecuada, proporcionar un enlace a la licencia, e indicar si se han realizado cambios. Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que tiene el apoyo del licenciante o lo recibe por el uso que hace de la obra.

[Resumen de licencia](#) – [Texto completo de la licencia](#)