



**UNIVERSIDAD
DEL PACÍFICO**

**Escuela de
Postgrado**

**“INNOVACIÓN EN LA SUPERVISIÓN DE LAS CONTRATACIONES
DEL ESTADO: APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL
PARA LA PREVENCIÓN DE IRREGULARIDADES EN
LICITACIONES PÚBLICAS”**

**Trabajo de Investigación presentado
para optar al Grado Académico de
Magíster en Gestión Pública**

**Presentado por
Francisco Roberto Bonnett Escobar**

Asesor: Ricardo Salazar Chávez

[0000-0002-0877-4620](tel:0000-0002-0877-4620)

Lima, septiembre 2025

Anexo III. Reporte de Evaluación Antiplagio




A través del presente, Juan Carlos Ubillús Ramírez deja constancia que el trabajo de investigación titulado "INNOVACIÓN EN LA SUPERVISIÓN DE LAS CONTRATACIONES DEL ESTADO: APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL PARA LA PREVENCIÓN DE IRREGULARIDADES EN LICITACIONES PÚBLICAS" presentado por don Francisco Roberto Bonnett Escobar con DNI 45550774, para optar al Grado de Magíster en Gestión Pública, fue sometido al análisis del sistema antiplagio turnitin el 23 de enero de 2025 dando el siguiente resultado:

The screenshot displays a Turnitin plagiarism report interface. On the left, a preview of the document is shown, featuring the logo of the Universidad del Pacífico Escuela de Postgrado and the title: "INNOVACIÓN EN LA SUPERVISIÓN DE LAS CONTRATACIONES DEL ESTADO: APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL PARA LA PREVENCIÓN DE IRREGULARIDADES EN LICITACIONES PÚBLICAS". On the right, a sidebar titled "Resumen de coincidencias" (Summary of coincidences) shows a total similarity score of 9%. Below the score, a list of six sources is provided, each with a percentage of similarity and a right-pointing arrow:

Rank	Source	Similarity
1	Entregado a Universid... Trabajo del estudiante	1 %
2	repositorio.uco.edu.pe Fuente de Internet	<1 %
3	repositorio.institucional... Fuente de Internet	<1 %
4	repositorio.upac.edu.pe Fuente de Internet	<1 %
5	tesis.pucp.edu.pe Fuente de Internet	<1 %
6	www.coursera.com Fuente de Internet	<1 %

23 de enero de 2025


Juan Carlos Ubillús Ramírez
Jefe Académico

Agradecimiento:

A mis padres y a mi futura esposa,
por ser motivación constante en mi
crecimiento profesional.

Resumen Ejecutivo

La presente investigación sustenta el diseño y validación de un modelo predictivo basado en inteligencia artificial, orientado a garantizar que las acciones de supervisión de segundo nivel que realiza por el Organismo Especializado para las Contrataciones Públicas Eficientes (OECE) tengan una cobertura del 100% de los procedimientos de licitación pública de bienes y obras convocados anualmente. Bajo ese marco, la metodología utilizada es de tipo aplicada, con un diseño no experimental y enfoque cuantitativo, la cual se apoya en una recopilación de datos provenientes de fuentes gubernamentales. El objetivo central es automatizar la detección temprana de deficiencias en las Bases Administrativas, permitiendo así mitigar riesgos de nulidad y prevenir la suscripción de contratos con vicios normativos; fortaleciendo, en última instancia, la transparencia y la eficiencia operativa en el uso de los recursos públicos.

El modelo predictivo, denominado “Revisor Inteligente de las Contrataciones Públicas” (REVICOP), ha sido desarrollado como una herramienta de apoyo para la supervisión de segundo nivel que realiza el OECE, bajo los principios de eficiencia y transparencia y buen uso de los recursos públicos, recomendando una adecuada guía y seguimiento para su consideración e implementación. En ese sentido, en su fase base el modelo alcanzó una precisión global del 67% (dos de cada tres predicciones correctas); no obstante, al incorporar una capa adicional de reglas lógicas determinísticas, que actúa como control normativo sobre las predicciones del modelo, la precisión superó el 90% con una métrica (F1-score) equilibrada en las tres categorías de salida (“Rechazado”, “Observado”, “Conforme”). Estos resultados se sustentan en el Capítulo V.

En dicho contexto, REVICOP tiene el potencial de mejorar la eficiencia operativa del OECE al reducir el tiempo de revisión y/o supervisión de los expedientes, y de manera automatizada. En suma, la presente investigación sustenta la viabilidad técnica y pertinencia institucional de implementar Inteligencia Artificial en la supervisión de las licitaciones públicas, contribuyendo a una gestión efectiva, moderna, ordenada y transparente del proceso de contratación pública.

Índice de contenido

Agradecimiento: -----	iii
Resumen Ejecutivo -----	iv
Índice de contenido -----	v
Índice de tablas -----	viii
Índice de figura -----	ix
Índice de Anexos -----	x
Capítulo I. Introducción -----	1
Capítulo II. Planteamiento del problema -----	2
2.1. Antecedentes: -----	2
2.2. Problema de investigación -----	5
Pregunta de investigación -----	6
2.3. Objetivos de la investigación -----	7
Objetivo general -----	7
Objetivos específicos -----	7
2.4. Justificación de la investigación -----	7
2.5. Delimitaciones: -----	10
2.6. Limitaciones:-----	10
2.7. Alcances: -----	11
Capítulo III. Marco conceptual -----	12
3.1. Marco teórico -----	12
3.1.1. Inteligencia Artificial-----	12
3.1.2. Procedimientos de licitación pública supervisados por el OECE -----	15
Capítulo IV. Marco metodológico -----	19
4.1. Tipo, Diseño y Enfoque de investigación-----	19

4.2. Alcance de investigación	19
4.3. Justificación del estudio	20
4.4. Procedimiento referente al desarrollo del modelo predictivo	21
4.5. Población y muestra	22
4.6. Recolección de datos	22
4.6.1. Fuentes primarias	22
4.6.2. Fuentes secundarias	23
Capítulo V. Resultados	24
5.1. Preprocesamiento y Preparación de Datos	24
5.2. Construcción del Modelo Predictivo	26
5.2.1. Selección de Variables y Conformación de la Matriz de Características	26
5.2.2. Arquitectura de la Red Neuronal (MLPClassifier)	29
5.2.3. División y Estratificación de Conjunto	29
5.2.4. Entrenamiento del Modelo	29
5.2.5. Ajuste Fino de Hiperparámetros	30
5.2.6. Validación Final y Guardado del Modelo	30
5.3. Evaluación del Modelo	31
5.3.1. Reporte de Clasificación	31
5.3.2. Matriz de Confusión	34
5.4. Implementación del Sistema Predictivo	36
5.5. Alineamiento con los Objetivos Específicos	37
5.6. Potencial de Escalamiento y Política Pública	38
Conclusiones y Recomendaciones	40
Conclusiones:	40
Recomendaciones:	42

Índice de tablas

Tabla 1 Procedimiento de selección.....	16
Tabla 2 Reporte de Clasificación	33

Índice de figura

Figura 1 Distribución de Clases	31
Figura 2 Distribución de Clases	35

Índice de Anexos

Anexo I. Propuesta de modificación del Reglamento de la Ley N° 32069 para incluir la Décimoquinta disposición complementaria final.....	47
Anexo II. Relación de Planes de Supervisión de los años 2022, 2023 y 2024.....	51
Anexo III. Relación de procedimientos supervisados de oficio por el OECE durante los años 2022, 2023 y 2024.....	52
Anexo IV. Resumen del cuestionario realizado a Funcionario Público del OECE.....	53
Anexo V. Interfaz del Revisor Inteligente de las Contrataciones Públicas.....	55
Anexo VI. Matriz de Entrenamiento y Diccionario de Variables de REVICOP.....	56

Capítulo I. Introducción

La presente investigación, propone innovar la supervisión de las Contrataciones del Estado con el desarrollo de un modelo predictivo basado en inteligencia artificial para la detección temprana de irregularidades en los procedimientos de licitación pública supervisados por el OECE. Dichas irregularidades pueden manifestarse en diversas formas, tales como, disposiciones contrarias a la normativa, errores de redacción u omisiones en las Bases Administrativas del procedimiento de selección.

Para la implementación de este modelo, se prevé la recopilación, procesamiento y análisis de datos provenientes del OECE. Estos datos permitirán la identificación de patrones y la generación de predicciones que faciliten una supervisión más eficiente y proactiva de los procesos de contratación pública.

En cuanto a la estructura del estudio, el Capítulo II desarrolla el planteamiento del problema, abordando en primer término los antecedentes de la investigación a partir de estudios previos tanto a nivel nacional como internacional sobre la supervisión de los procedimientos de licitación pública. Posteriormente, se presenta la formulación del problema de investigación y los objetivos generales y específicos del estudio. Asimismo, se exponen la justificación de la investigación, las delimitaciones del estudio, sus limitaciones y los alcances esperados.

Capítulo II. Planteamiento del problema

2.1. Antecedentes:

La innovación de la supervisión de las Licitaciones Públicas, a través del desarrollo de un modelo predictivo basado en inteligencia artificial, es el eje central de esta investigación. Sin embargo, aunque la metodología se enfoca en la evaluación de los procedimientos de licitación pública de bienes y obras bajo la competencia del OECE, se han revisado antecedentes en diversos contextos geográficos e institucionales para proporcionar un enfoque integral y comparativo; esto incluye el análisis de experiencias internacionales en la gestión de riesgos contractuales y estudios nacionales en distintos niveles de la administración pública peruana.

A nivel internacional, Cruz y Sarmiento (2023) identificaron malas prácticas en la contratación pública en Colombia, donde la falta de vigilancia rigurosa por parte de los entes de control compromete la transparencia y el uso eficiente de los recursos públicos. La ausencia de mecanismos adecuados de fiscalización propicia sobrecostos y corrupción, afectando la objetividad de los procesos y favoreciendo adjudicaciones poco competitivas.

Por su parte, Sabogal (2023) señaló que la contratación pública en Colombia enfrenta riesgos significativos debido a la magnitud de los proyectos y a la deficiente supervisión interna. Esto permite que ciertos funcionarios manipulen los requisitos para beneficiar a proveedores específicos, lo que genera riesgos legales, disminuye la rentabilidad y limita la supervisión efectiva de los contratos. Además, el criterio predominante de selección basado en precios, en lugar de calidad, fomenta la cartelización y la adquisición de bienes y servicios deficientes.

Arenas (2023), analizó el desempeño del departamento de Infraestructura de la Alcaldía de Bucaramanga Santander, enfocándose en las actividades técnico administrativas relacionadas con la supervisión de proyectos. El objetivo fue garantizar la calidad y seguridad de los proyectos, prevenir errores, gestionar el control de tiempos y cumplir con los planes de los proyectos. Se adquirieron conocimientos en procesos técnico-administrativos, incluyendo las etapas contractuales y post contractuales, y el proceso de ejecución y terminación de contratos. Se realizó el análisis presupuestal, identificando inequidades y requerimientos de intervención. Se realizaron visitas técnicas para asegurar la ejecución de los proyectos, identificando pequeñas fallas y abordándolas. El estudio reveló problemas de inequidad presupuestaria, deficiencias en diseño y calidad de materiales, así como fallos en los procesos constructivos,

factores que generan sobrecostos y retrasos en la ejecución de proyectos.

Estrada (2023) evaluó el impacto del control interno en los pagos públicos mediante catálogos electrónicos en una Agencia Fiscal Superior de Ecuador. La investigación utiliza una metodología mixta, incluyendo un estudio cuantitativo utilizando datos oficiales para evaluar el cumplimiento de los controles internos y un enfoque cualitativo a través de entrevistas a empleados de unidades dispersas. El principal resultado fue que los procesos actuales de contratación por catálogo electrónico involucran 42 actividades y una demora de aproximadamente 87 días, con una demora promedio de 46 días hasta que se realiza el pago. El estudio propone dos procesos de control interno y acciones para ayudar a la EFS del Ecuador a considerarlos para extender las actividades de compras públicas en todas las unidades dispersas.

Viscarra y González (2021) realizaron un análisis histórico sobre la administración y contratación pública en Ecuador, detectando desajustes entre la legislación vigente y los objetivos de planificación nacional. Se propusieron reformas para alinear los procesos de adquisición pública con los principios de transparencia y eficiencia.

A nivel nacional, Mamani (2025) estudió los riesgos en la contratación y ejecución de obras públicas en una municipalidad distrital entre 2021 y 2023. La metodología utilizada fue cualitativa, básica, teórica, fenomenológica, etnográfica y descriptiva, se utilizó una muestra de 17 trabajadores y se realizaron entrevistas a 5 profesionales. Los hallazgos revelaron que los contratos públicos impactan significativamente en la contratación y ejecución de obras en la Municipalidad Distrital de Huata, ocasionando retrasos, conflictos de interés y demoras en los estudios de mercado. Estos riesgos también afectan los actos preparatorios para la contratación y ejecución de obras, pues el personal responsable de estos contratos es crucial para evitar consecuencias negativas y asegurar la correcta terminación de la obra. Además, los contratos públicos afectan significativamente la selección y ejecución contractual de obras en la Municipalidad Distrital de Huata, presentándose diversas circunstancias como retrasos, documentos falsificados y numerosas observaciones, controversias y sanciones que afectan la efectiva terminación y culminación de la obra, afectando en última instancia a la sociedad.

Ureta (2024) señaló que el propósito de la supervisión es prevenir posibles inconsistencias en la normativa de los contratos con el Estado, mediante acciones preventivas y correctivas. En 2021 y 2022 se supervisaron 36 y 67 procedimientos de selección, identificándose 322 y 532 deficiencias. En 2023 se supervisaron 15 entidades y 109 procedimientos de selección con el

objetivo de reducir riesgos en contrataciones y mejorar la eficiencia en la emisión de pronunciamientos.

Moreno y Santos (2023) propusieron un sistema de indicadores para establecer alertas de corrupción en la selección y consultoría de obras públicas en el Perú. Se utilizó un enfoque cualitativo, combinando técnicas de documentación con técnicas de investigación de campo como entrevistas. Se tuvo como resultado que mapeando la Corrupción, metodología desarrollada por el Instituto Mexicano para la Competitividad (IMCO), que permite identificar alertas de corrupción en Perú; además, se aplica a contratos públicos de obras y consultoría, potenciando los esfuerzos anticorrupción. El uso de blockchain y machine learning permite la detección temprana y la ejecución contractual; también se indica que la metodología también genera indicadores de selección para los proyectos 2021 y 2022, identificando posibles riesgos de favoritismo y coparticipación.

Carcheri (2023) evaluó si los procedimientos estipulados en la Ley de Contrataciones Públicas para las contrataciones menores a ocho UIT, cumplen con los principios de Concurrencia y Competencia en el Ministerio de la Mujer y Poblaciones Vulnerables (MIMP). La metodología adoptada fue cuantitativa, descriptiva, no experimental y transversal. Los hallazgos indicaron que los procedimientos están claramente establecidos e institucionalizados en el MIMP, y los procedimientos, mecanismos e instrumentos para supervisar dichos procedimientos cumplen con las normas establecidas. La investigación determina que tanto el personal como el representante designado por el OECE poseen una comprensión clara de la legislación, dado que disponen de una estructura organizativa que facilita la toma de decisiones concretas.

Luna (2022) analizó las ineficiencias en las adquisiciones públicas en Perú entre 2016 y 2021, identificando una alta tasa de procesos desiertos en comparación con Chile, Uruguay, República Dominicana y España. Propuso estrategias como la optimización del RNP y el "Programa Nacional de Ganadores de MYPE" para incrementar la participación y reducir la deserción en procesos de selección.

Patricio (2021) identificó conflictos en contrataciones públicas y propuso modificaciones normativas en ocho artículos de la Ley de Contrataciones del Estado, con el fin de reducir la discrecionalidad y mejorar la eficiencia en adquisiciones. El estudio se fundamenta en una base teórica autorizada por la legislación y reglamento de contrataciones del Estado, junto con sus correspondientes modificaciones y estudios análogos realizados por otros expertos en

licitación. Se llevó a cabo un análisis de una muestra de 250 individuos con experiencia en el ámbito de las compras públicas, mediante una serie de entrevistas que culminan en la formulación de una Propuesta Normativa.

Estos antecedentes evidencian la necesidad de fortalecer los sistemas de contratación pública mediante controles internos rigurosos, el uso de tecnologías emergentes y reformas normativas que garanticen transparencia, eficiencia y el uso adecuado de los recursos públicos.

2.2. Problema de investigación

En el ámbito nacional, la Dirección de Supervisión y Asistencia Técnica del OECE (anteriormente Dirección de Gestión de Riesgos del OSCE) enfrenta desafíos significativos en su rol de supervisión de las contrataciones públicas. Estos problemas se manifiestan en la limitada efectividad de las acciones de supervisión sobre el total de licitaciones convocadas año tras año, a causa de la insuficiente cantidad de recursos humanos, presupuestales y tecnológicos. Por lo tanto, a pesar de que la supervisión constituye una de las responsabilidades neurálgicas del OECE, en la práctica su función se percibe como restringida debido a la falta de recursos que le permitan una cobertura total de las Licitaciones Públicas convocadas en el país.

Al respecto, la identificación del problema descrito precedentemente, se fundamenta en evidencia operativa concreta y corroborada por el propio OECE. En relación con ello, según los datos obtenidos de la consulta realizada al Subdirector de Atención de Elevación de Cuestionamientos para efectos de esta investigación, se determinó que en el año 2023 (febrero - junio), de los 2284 procesos de Licitación Pública y Concursos Públicos convocados, solo se supervisaron 20 procesos, es decir, el 0.88% del universo total; vale acotar, que la meta anual fijada por el OECE para el 2023 era solo de 108 procesos supervisados, lo cual significa una meta significativamente reducida en comparación con el volumen de contrataciones sobre el universo de procesos convocados anualmente. Cabe resaltar que, a pesar de la baja muestra, en solo estos 20 procedimientos supervisados, se identificaron 142 deficiencias técnicas y normativas, es decir, un promedio de 7.1 transgresiones por proceso. Por su parte, según la información alcanzada por el OECE, para el 2022 se estableció la meta de supervisar solo 60 procesos de selección en el año, a lo que ellos superaron la meta alcanzando la supervisión de 67 procesos (52% CP y 48% LP) en todo el 2022, y precisan que en dichos 67 procedimientos, identificaron 532 deficiencias (Anexos II y III). Como dato adicional, la meta de acciones de

supervisión en licitaciones públicas y concursos públicos para el año 2024, solo fue de 180 procedimientos de selección, mientras que el total de Licitaciones Públicas (bienes y obras) convocadas en ese año fue de 4897, conforme los datos publicados en el portal web de CONOSCE (OSCE, s.f.).

Adicionalmente, se comprobó que las irregularidades más recurrentes se concentran específicamente en incongruencia en el contenido integral de las Bases, no se utilizó las Bases Estándar correspondientes y deficiencia en el expediente técnico de obra (Anexos II y III) .

Atendiendo a este escenario, Castro L. (2022) sostiene que la Dirección de Supervisión y Asistencia Técnica debería reevaluar de manera urgente su estrategia de supervisión y la asignación de recursos para asegurar que las entidades cumplan con el marco normativo, contribuyendo así a la mejora de la calidad de vida de los ciudadanos. En consecuencia, surge la necesidad de implementar soluciones disruptivas que permitan transitar de una supervisión manual y reactiva hacia una proactiva y automatizada.

Por consiguiente, la implementación del modelo predictivo REVICOP, basado en inteligencia artificial, se propone como una solución innovadora para advertir de manera temprana las deficiencias en las Bases Administrativas. En ese sentido, el objetivo central es reducir los riesgos de deficiencias en los procedimientos de selección y evitar la suscripción de contratos con vicios. En suma, esta herramienta busca fortalecer la transparencia y la eficiencia en el uso de los recursos públicos, optimizando la capacidad de respuesta institucional frente a los desafíos detectados en la supervisión de segundo nivel.

Pregunta de investigación

Problema general

¿De qué manera la implementación de un modelo predictivo basado en inteligencia artificial permite superar las limitaciones de cobertura de la supervisión muestral del OECE, optimizando la detección de irregularidades en las Licitaciones Públicas?

Problemas específicos

- ¿En qué medida la automatización mediante el modelo predictivo mejora la precisión

en la detección temprana de vicios formales y normativos en las Bases Administrativas frente a la revisión manual tradicional?

- ¿Cómo impacta el uso del modelo predictivo en el incremento del alcance operativo de la supervisión del OECE, permitiendo transitar de un esquema selectivo a una cobertura del 100% de los procedimientos de Licitación Pública?
- ¿De qué forma el modelo predictivo contribuye a la eficiencia del gasto público al automatizar la carga operativa de la verificación documental, reduciendo los costos y tiempos asociados a la supervisión tradicional?

2.3. Objetivos de la investigación

Objetivo general

Determinar de qué manera la implementación de un modelo predictivo basado en inteligencia artificial permite superar las limitaciones de cobertura de la supervisión muestral del OECE, optimizando la detección de irregularidades en las Licitaciones Públicas de bienes y obras.

Objetivos específicos

- Determinar en qué medida la automatización mediante el modelo predictivo mejora la precisión en la detección temprana de vicios formales y normativos en las Bases Administrativas frente a la revisión manual tradicional.
- Determinar el impacto del uso del modelo predictivo en el incremento del alcance operativo de la supervisión del OECE, permitiendo transitar de un esquema selectivo a una cobertura del 100% de los procedimientos de Licitación Pública.
- Determinar de qué forma el modelo predictivo contribuye a la eficiencia del gasto público al automatizar la carga operativa de la verificación documental, reduciendo los costos y tiempos asociados a la supervisión tradicional.

2.4. Justificación de la investigación

Justificación teórica:

La integración de un modelo predictivo basado en inteligencia artificial aporta un enfoque

teórico que combina tecnología avanzada y contratación pública, enriqueciendo el estudio académico de la gestión pública y sentando las bases para la modernización de los procesos de contratación y supervisión.

Justificación práctica:

El uso de herramientas de inteligencia artificial en el análisis de las bases de licitación agiliza y mejora la precisión en la identificación de irregularidades, reduciendo la dependencia del factor humano. Esto permite detectar errores y vulnerabilidades de manera oportuna, garantizando el cumplimiento del marco normativo, minimizando demoras y optimizando los recursos públicos, lo que resulta en procesos de contratación más eficientes y transparentes.

Justificación metodológica:

La investigación adopta la tipología de aplicada con un enfoque cuantitativo, descriptivo y propositivo, combinando encuestas y análisis documental. Este diseño facilita la recolección y procesamiento de datos secundarios provenientes de fuentes oficiales, como el SEACE/PLADICOP y el OECE, para identificar tendencias y establecer indicadores que sustenten el desarrollo y validación del modelo predictivo. La metodología asegura objetividad y replicabilidad, aportando rigor científico al estudio.

Justificación social:

La implementación de un modelo predictivo basado en inteligencia artificial en el ámbito de la contratación pública incide directamente en la eficiencia del uso de los recursos públicos. Al anticipar y otorgar la posibilidad de corregir irregularidades en los procedimientos de licitación, se reduce el riesgo de retrasos en el cumplimiento de los objetivos públicos inherentes a dichos procesos, y se fortalece la transparencia y la confianza ciudadana en la gestión estatal, con beneficios directos para la sociedad.

Justificación normativa:

El desarrollo e implementación del modelo REVICOP se encuentra alineado con los principales instrumentos normativos y estratégicos del Estado peruano que promueven la transformación digital, la inteligencia artificial y el uso eficiente de los datos públicos, tales como:

- **Ley N.º 31814, Ley que Promueve el Uso de la Inteligencia Artificial en favor del Desarrollo Económico y Social del País**, que promueve uso de la inteligencia artificial en el marco del proceso nacional de transformación digital.
- **Ley N.º 27658, Ley Marco de Modernización de la Gestión del Estado**, que establece como principios orientadores la eficiencia, transparencia, orientación a resultados y el uso intensivo de tecnologías de información para mejorar los servicios públicos.
- **Decreto Legislativo N.º 1412, Decreto Legislativo de Gobierno Digital**, que reconoce el uso de tecnologías disruptivas como la inteligencia artificial como parte de la estrategia del Estado para garantizar servicios digitales accesibles, seguros y basados en evidencia.
- **Decreto Supremo N.º 115-2025-PCM, que aprueba el Reglamento de la Ley N.º 31814**, Ley que promueve el uso de la inteligencia artificial en favor del desarrollo económico y social del país.
- **Decreto Supremo N.º 029-2021-PCM, que aprueba la Política Nacional de Transformación Digital**, cuyo eje prioritario incluye el uso intensivo de tecnologías como la inteligencia artificial para fortalecer las capacidades del sector público en la toma de decisiones basada en datos.
- **Decreto Supremo N.º 157-2021-PCM, que aprueba la Política Nacional de Datos Abiertos Gubernamentales al 2030**, donde se promueve el aprovechamiento del valor de los datos públicos, su interoperabilidad y su reutilización para generar soluciones de valor público.
- **Plan Estratégico de Tecnologías Digitales del MEF y la Dirección General de Abastecimiento (2023–2027)**, donde se prioriza el fortalecimiento del PLADICOP/SEACE como plataforma de supervisión inteligente y automatizada en contrataciones públicas.

Este marco normativo permite gestionar la incorporación de modelos predictivos en las contrataciones públicas, como parte de una supervisión moderna, preventiva y basada en evidencia.

Asimismo, la implementación de REVICOP se alinea con el fortalecimiento del Sistema de Control Interno (SCI). Al automatizar la detección de irregularidades en la supervisión de segundo nivel, se genera un efecto de retroalimentación hacia el primer nivel de control, obligando a las Entidades a mejorar sus procesos de elaboración de bases. De este modo, la herramienta no solo optimiza la labor del OECE, sino que se inserta como un mecanismo preventivo que eleva los estándares de integridad y legalidad en todo el ecosistema de la contratación pública

2.5. Delimitaciones:

- El modelo predictivo se vinculará a la PLADICOP.
- El desarrollo e implementación del modelo predictivo basado en inteligencia artificial, se gestionará durante los años 2025 - 2026.
- El impacto social derivado de la detección en tiempo real de irregularidades, analizando cómo esta herramienta mejora la transparencia y eficacia en la contratación pública.

2.6. Limitaciones:

- La investigación depende de la aprobación institucional para la evaluación del modelo predictivo basado en inteligencia artificial, lo que puede limitar el acceso a datos completos y actualizados.
- Se realizará una prueba piloto con una base de datos resumida, lo que podría restringir la generalización de los resultados a todo el sistema.
- La disponibilidad de información estadística y la colaboración de funcionarios del OECE para entrevistas y encuestas pueden representar obstáculos adicionales en el proceso de recolección de datos.
- El modelo predictivo actual carece de la intuición necesaria para detectar direccionamientos o favoritismos sutiles que se encuentren formalmente dentro de los documentos de los procedimientos de selección. Su alcance se restringe a la validación de cumplimiento y detección de vicios formales en las Bases Administrativas.

2.7. Alcances:

- La investigación posee un alcance nacional y se orienta a la identificación temprana de deficiencias técnicas y normativas en el universo de licitaciones públicas de bienes y obras sujetas a la supervisión del OECE. Este propósito se materializa mediante la validación del modelo predictivo REVICOP, sustentado en inteligencia artificial para garantizar un control preventivo integral.
- Se espera que la implementación de esta herramienta contribuya a la reducción de errores, deficiencias y vulnerabilidades en los procesos de contratación, optimizando el uso de recursos públicos y fortaleciendo la transparencia en la gestión estatal.
- Los resultados del estudio podrían servir como base para futuras modificaciones normativas en la Ley General de Contrataciones del Estado, promoviendo la adopción obligatoria de inteligencia artificial en la supervisión de licitaciones públicas.

Capítulo III. Marco conceptual

3.1. Marco teórico

3.1.1. Inteligencia Artificial

La Inteligencia Artificial (IA) ha impactado significativamente en múltiples disciplinas, incluyendo la educación, donde ha introducido transformaciones importantes en los métodos de enseñanza. Sin embargo, para garantizar su éxito sostenido, es fundamental abordar los desafíos éticos y sociales asociados con su implementación en este ámbito. Bolaño-García y Duarte-Acosta (2024) subrayan la importancia de intensificar la investigación y el desarrollo para perfeccionar la calidad de los datos y mitigar las preocupaciones éticas y sociales vinculadas al uso de la IA en la educación.

3.1.1.1. Modelo de inferencia de contexto

Un modelo de inferencia de contexto en el campo de la inteligencia artificial alude a un sistema que examina y comprende el contexto de un diálogo, texto o ambiente con el objetivo de optimizar su capacidad de respuesta o toma de decisiones. Existen diversas metodologías para la inferencia de contexto en la Inteligencia Artificial, y algunos académicos de renombre han formulado teorías y modelos significativos en este ámbito.

Bidirectional Encoder Representations from Transformers (BERT)

BERT, desarrollado por Google, es una arquitectura de transformación bidireccional que soporta representación multilingüe en 104 idiomas. Su funcionamiento se divide en dos etapas: preentrenamiento y ajuste fino. Utiliza la tokenización WordPiece, basada en Byte Pair Encoding (BPE), para dividir el texto en tokens disponibles en su diccionario. Las incrustaciones contextuales de BERT pueden ser a nivel de palabra o de oración, adaptándose al contexto específico (Deepa y Tamilarasi, 2021).

Las tareas de preentrenamiento de BERT incluyen el Modelo de lenguaje enmascarado (MLM) y la Predicción de la siguiente oración (NSP). El codificador del transformador lee la secuencia completa de palabras y aprende el contexto de una palabra basándose en todas las palabras que la rodean. La representación de entrada de cada oración se obtiene mediante la suma de la incrustación posicional, la incrustación de segmento y las incrustaciones de palabras. Las tareas de ajuste fino de BERT agregan una capa no entrenada en la parte superior de la capa de salida,

lo que permite dedicar menos tiempo y energía a entrenar el modelo (Deepa y Tamilarasi, 2021).

Generative Pre-trained Transformers (GPT)

El modelo GPT representa una categoría de modelo DL que emplea aprendizaje auto supervisado para entrenar volúmenes considerables de datos textuales, lo que posibilita la generación de una salida de lenguaje de alta calidad. Los avances recientes en la investigación del modelo GPT pueden favorecer la optimización continua de su arquitectura, la ampliación de la disponibilidad de potencia informática y la creación de nuevas técnicas para adaptar el modelo a tareas particulares. Estos avances han propiciado la generación de modelos GPT de mayor tamaño y potencia, permitiendo así la ejecución de un espectro más extenso de tareas de PNL con precisión y fluidez sin precedentes (Yenduri et al., 2024).

Estos modelos GPT han evidenciado un considerable potencial en la transformación de diversas industrias, incluyendo la asistencia sanitaria, el servicio al cliente y la industria financiera, entre otras. El propósito de esta revisión bibliográfica es examinar los descubrimientos y aportaciones fundamentales de los artículos de investigación más recientes sobre modelos GPT, con el fin de ofrecer una comprensión exhaustiva y contemporánea del estado actual del arte en constante evolución (Yenduri et al., 2024).

Text-to-Text Transfer Transformer (T5)

Es una tarea de regresión que apunta a predecir puntuaciones de similitud entre 1 y 5. Para convertir las puntuaciones al incremento de 0,2 más cercano, el modelo se redondea al 0,2 más cercano y se convierte en una representación de cadena literal. El problema de regresión STS-B se reformula como un problema de clasificación de 21 clases. El modelo también se puede utilizar en el marco de texto a texto mediante la concatenación de entradas y objetivos, como se demostró en un estudio reciente que muestra que los modelos de lenguaje pueden aprender a realizar tareas de texto a texto sin supervisión (Raffel et al., 2020).

3.1.1.2. Modelo de inferencia de contexto por predicción basado en la técnica de IA: Redes neuronales artificiales

Las Redes Neuronales Artificiales (RNA), es una clase de aprendizaje profundo, son conocidas por su capacidad de procesar y obtener datos secuenciales; además, sus capacidades incluyen análisis de video, subtítulos de imágenes, procesamiento de lenguaje natural y análisis de

música. Las Redes Neuronales Recurrentes (RNN) capturan dependencias secuenciales y temporales, a diferencia de las redes neuronales artificiales que asumen independencia entre la entrada de datos, se indica que uno de sus atributos más importantes es el intercambio de sus parámetros, lo que permite una interpretación más precisa del lenguaje natural. Las RNN también aumentan la arquitectura de las redes multicapacidad convencionales al agregar ciclos que conectan nodos adyacentes o pasos de tiempo. Pueden realizar múltiples mapas, como traducir o identificar una voz, utilizando un gráfico computacional (Arana, 2021).

La inferencia de contexto en IA implica la capacidad de un sistema de comprender información implícita en los datos y hacer predicciones precisas; además, se indica que la captura patrones latentes en secuencias de datos y se puede aplicar en el procesamiento del lenguaje natural, la visión artificial y los sistemas de recomendación, basándose en el estado anterior para mejorar las predicciones futuras.

Redes Neuronales Recurrentes (RNN)

Las Redes Neuronales Recurrentes (RNNs) son modelos de redes neuronales artificiales (RNA) que forman un ciclo dirigido entre unidades, utilizadas para el reconocimiento de voz y escritura, y para procesar datos estructurados; están compuestas por neuronas recurrentes con un agujero de retroalimentación. Pueden realizar simultáneamente una secuencia de entradas y salidas, utilizar sus experiencias previas para informar eventos futuros, analizar secuencias temporales y procesar datos que cambian con el tiempo. Su principal ventaja es la capacidad de almacenar una representación de la historia reciente de la secuencia. Las RNN pueden analizar secuencias temporales de datos variables y predecir el siguiente valor de la serie. Se pueden categorizar en parciales o totalmente recurrentes, con redes parcialmente recurrentes que tienen conexiones finitas y conexiones recurrentes (Castillo y Ávila, 2024).

Long Short-Term Memory (LSTM)

La gestión de procesos de negocio requiere sistemas de información para predecir el comportamiento futuro del proceso; respecto a los métodos de monitoreo de procesos de negocios utilizan registros de eventos para hacer predicciones sobre casos de ejecución. La implementación de redes neuronales LSTM para el descubrimiento de eventos o actividades es una estrategia importante en la minería de procesos; se indica que esto se basa en una red neuronal recurrente LSTM que es entrenada con un registro de eventos (Ramírez et al., 2018).

Gated Recurrent Units (GRU)

La red neuronal recurrente con unidades recurrentes controladas (GRU), un perceptrón multicapa y un módulo softmax. El sistema utiliza GRU como unidades de memoria principal y un perceptrón multicapa para identificar intrusiones en la red. El sistema se evaluó en los conjuntos de datos KDD 99 y NSL-KDD, y se demostró que las GRU son más adecuadas para la detección de intrusiones que la memoria a corto plazo (LSTM). La red neuronal profunda reduce la carga de trabajo de los expertos en redes y ofrece resultados positivos en el cambiante entorno de redes actual (Xu et al., 2018).

3.1.1.3. Modelo de inferencia de contexto basado en la técnica de IA: Sistema basado en reglas

Los sistemas basados en reglas han representado uno de los métodos más antiguos y confiables en el campo de la inteligencia artificial (IA) para la inferencia de contexto. Emplean un conjunto preestablecido de normas lógicas para la interpretación, análisis y gestión de información contextual en una variedad de contextos, tales como chatbots, sistemas especializados y automatización de procesos de decisión.

Forward Chaining

El desarrollo de un sistema de gestión del aprendizaje tiene como objetivo brindar apoyo a los usuarios en la identificación de brechas de aprendizaje sin requerir interacción con el usuario, reduciendo así el tiempo y el esfuerzo necesarios para resolver problemas. El sistema utiliza el encadenamiento hacia adelante como mecanismo de inferencia, lo que permite la transferencia de conocimientos, información y experiencias de los estudiantes con la eficiencia de un sistema (Sapriadi et al., 2023).

El sistema de gestión del aprendizaje para identificar las brechas de aprendizaje es beneficioso para los docentes en el desarrollo de sus actividades docentes; también incluye una función Blackbox, que permite la validación de las brechas de aprendizaje. El desarrollo de un sistema de gestión del aprendizaje es crucial para abordar las brechas de aprendizaje y mejorar la experiencia de aprendizaje en general (Sapriadi et al., 2023).

3.1.2. Procedimientos de licitación pública supervisados por el OECE

Es fundamental precisar que, dentro del Sistema de Control Interno de la administración pública, la supervisión se estructura por niveles. En dicho contexto, las Entidades contratantes

ejecutan una **supervisión de primer nivel**, la cual es intrínseca a su gestión operativa y responsabilidad administrativa. No obstante, la presente investigación se enfoca en la **supervisión de segundo nivel** que ejerce el OECE. Esta última es una supervisión técnica y especializada que busca verificar el cumplimiento normativo de las actuaciones del primer nivel, funcionando como un filtro crítico para mitigar riesgos antes de que intervenga el control gubernamental externo (tercer nivel).

El Organismo Especializado para las Contrataciones Públicas Eficientes constituye una entidad técnica especializada vinculada al Ministerio de Economía y Finanzas (MEF). Su responsabilidad primordial radica en la supervisión y fomento del cumplimiento de las regulaciones en las contrataciones públicas, garantizando que los procedimientos de adquisición de bienes, servicios y obras por parte del Estado sean íntegros, eficaces y competitivos (Plataforma del Estado, 2025).

El OECE lleva a cabo una supervisión selectiva y aleatoria de los procesos de selección, incluyendo las licitaciones públicas, con el objetivo de garantizar la adhesión a las regulaciones y fomentar las prácticas óptimas en el ámbito de la contratación pública. Además, gestiona el SEACE que se encuentra dentro del PLADICOP, que asegura la transparencia e información accesible (Congreso, 2022).

3.1.2.1. Procedimiento de selección

La licitación pública se define como un procedimiento de selección competitivo mediante el cual el Estado convoca a proveedores interesados para disputar la adjudicación de un contrato de bienes u obras. **Al respecto**, este mecanismo se caracteriza fundamentalmente por su aplicación en contrataciones de alta cuantía económica; **en ese sentido**, para el ejercicio fiscal 2026, se ha determinado que las licitaciones públicas de bienes se convocarán a partir de los S/ 485,000.00, mientras que para el caso de obras el umbral se establece desde los S/ 5,000,000.00.

Este procedimiento asegura transparencia, equidad en las oportunidades y la elección de la oferta óptima; y cuenta con características como las siguientes:

Tabla 1

Procedimiento de selección

Competencia	Pública y Abierta. Se rige por el Principio de
--------------------	--

	Libertad de Concurrencia, permitiendo la participación de todo proveedor inscrito en el RNP. Se distingue de otros procedimientos selectivos que operan mediante listas cerradas o invitación directa (ej. Comparación de Precios, Concurso Público con Diálogo Competitivo, etc).
Tiempo de proceso	Largo, con varias etapas.
Criterios de selección	Mejor relación calidad-precio en competencia.
Transparencia	Alta, con amplia difusión pública.
Enfoque	Valor por dinero, cumplimiento de requisitos y precio.
Criterios de evaluación	Bajo el enfoque de Valor por Dinero, los criterios de evaluación ponderan la calidad sobre el costo. En el caso de Bienes, la oferta económica tiene un puntaje máximo de 40, otorgándose el mayor peso a los factores técnicos (sostenibilidad, mejoras, certificaciones). En Obras, la evaluación prioriza la capacidad técnica y profesional, y el puntaje de la oferta económica es ponderado.
Uso	Bienes y obras.

3.1.2.2. Categorías y niveles de cumplimiento en la supervisión

Para la presente investigación, se han establecido tres categorías operativas que definen el alcance de la validez del expediente revisado por REVICOP:

- **Conforme:** Representa el estado de alineamiento integral con la normativa de contrataciones y las Bases Estándar. Asimismo, implica que el documento no presenta riesgos técnicos ni vicios, resultando apto para continuar con el procedimiento de selección sin observaciones.
- **Observado:** Define un nivel de incumplimiento parcial o no crítico. Por ejemplo, se refiere a omisiones de cláusulas facultativas, errores de redacción o falta de precisión en datos que, no obstante, pueden ser subsanados por la entidad sin invalidar la estructura del procedimiento .

- Rechazado: Constituye el nivel de invalidez estructural. En consecuencia, esta categoría se reserva para hallazgos críticos, como la inadecuación del objeto de contratación o vulneraciones directas a principios de la Ley, situaciones que comprometen la legalidad del expediente y exigen su reformulación total o declaratoria de nulidad .

Por lo tanto, estos niveles permiten que la entidad adopte una respuesta adecuada frente al resultado emitido por el REVICOP.

Capítulo IV. Marco metodológico

4.1. Tipo, Diseño y Enfoque de investigación

El tipo de investigación será aplicada, por cuanto el estudio científico se centra en resolver los conflictos prácticos que se desarrollan en la vida cotidiana a través de la implementación del método científico para contribuir con soluciones a los hallazgos. Se indica que, las tecnologías innovadoras permiten contribuir a la eficacia, eficiencia e impacto de las intervenciones, así como políticas e iniciativas (Castro et al., 2023).

El diseño de investigación adoptado es de tipo no experimental, en tanto no se manipularán deliberadamente las variables, sino que se observarán en su contexto natural. Esta estrategia permite analizar el fenómeno bajo estudio en condiciones reales, considerando su evolución en distintos entornos institucionales y contextos operativos. Además, en el presente estudio no se desarrollará ninguna incidencia ni alteración que tiene las variables alineado con los autores previos. También se alinearán un nivel longitudinal evaluando la tendencia y evolución de los datos obtenidos (Hadi et al., 2023).

El enfoque cuantitativo para el desarrollo de la investigación se concentra en la determinación de la medición y análisis a nivel numérico de la base de datos para el desarrollo de los patrones estadísticos de la hipótesis formulada entre las variables con sus respectivas dimensiones; alineado a las objetividades con un método deductivo a través de las herramientas estandarizados (Huamán et al., 2022). Este enfoque permitirá determinar la eficacia que tiene la implementación de una técnica de aprendizaje automatizada respecto a las licitaciones públicas a través del modelo predictivo.

4.2. Alcance de investigación

En primer término, la investigación adopta un alcance de tipo exploratorio, el cual resulta fundamental debido al carácter innovador y disruptivo que representa el uso de inteligencia artificial en la supervisión de las contrataciones del Estado peruano. En ese sentido, este nivel de investigación permite una aproximación inicial a un fenómeno poco estudiado, facilitando la comprensión del problema y orientando la indagación hacia la identificación de patrones dentro de las bases de datos gubernamentales. Asimismo, este enfoque permite evaluar la percepción pública y técnica sobre la eficacia del modelo predictivo propuesto, considerando

las características particulares de las irregularidades detectadas en la información recopilada. (Ramos, 2020).

Por otro lado, el estudio se sitúa en un nivel descriptivo, por cuanto se orienta a caracterizar y detallar de forma sistemática las deficiencias técnicas y normativas que componen la problemática de la supervisión de licitaciones públicas. Al respecto, este alcance se centra en el análisis de las variables críticas seleccionadas, considerando su evolución geográfica y temporal, así como las tendencias estadísticas que emergen de la matriz de datos. (Guevara et al., 2020).

4.3. Justificación del estudio

La presente investigación se justifica en la necesidad de modernizar la supervisión de las licitaciones públicas, transitando de un modelo manual y muestral hacia uno automatizado de cobertura masiva. Bajo ese marco, la indagación se fundamenta en los siguientes criterios:

En primer término, desde una perspectiva técnica y estratégica, se evalúa la implementación de un modelo predictivo sustentado en inteligencia artificial para superar las actuales limitaciones de cobertura institucional. Al respecto, la importancia de REVICOP radica en su capacidad algorítmica para advertir tempranamente irregularidades normativas en el 100% de los procedimientos de licitación pública supervisados por el OECE, garantizando una detección de vicios formales que la revisión manual no puede alcanzar debido a la alta carga documental.

En segundo término, el estudio se justifica operativamente por su contribución directa a la eficiencia del gasto público. El modelo propuesto permite optimizar los recursos institucionales al reducir drásticamente los tiempos de verificación documental, pasando de un promedio de 2 horas a aproximadamente 15 minutos en la revisión de las bases administrativas, de manera automatizada.

En ese sentido, esta celeridad permite mitigar riesgos de nulidad de forma oportuna y previene la suscripción de contratos con deficiencias legales; asimismo, se prevé que el sistema genere en las entidades una mayor predisposición por velar por el cumplimiento normativo desde la etapa preparatoria de las Bases.

Finalmente, la investigación posee una justificación metodológica integral. Tras la validación

del modelo predictivo, se aplicará un instrumento de evaluación orientado a medir su eficacia percibida por los profesionales expertos involucrados en la contratación pública. Por consiguiente, este insumo permitirá complementar la validación estadística de la inteligencia artificial con una perspectiva cualitativa sobre su utilidad práctica, viabilidad técnica y pertinencia institucional en la gestión pública moderna.

4.4. Procedimiento referente al desarrollo del modelo predictivo

El desarrollo del modelo predictivo se orientará a la identificación y determinación técnica de las irregularidades más recurrentes en los procedimientos de licitación pública. Al respecto, se consideran fallas críticas tales como la omisión de disposiciones normativas, así como inconsistencias sustanciales en la definición del objeto y la finalidad pública, entre otros hallazgos de relevancia. En ese contexto, resulta fundamental establecer los criterios de éxito para validar la utilidad del modelo mediante métricas de desempeño estandarizadas, incluyendo la precisión (precision), el recall y el F1-Score.

Respecto a la fase de recopilación y procesamiento de información, se ha diseñado una matriz de datos simulados que replican fielmente las irregularidades identificadas en los registros históricos de los años 2022, 2023 y 2024 de las licitaciones públicas supervisadas por el OECE; dicho insumo constituye la base fundamental para el entrenamiento del modelo. Posteriormente, durante el preprocesamiento de estos datos, se procederá con la limpieza y el tratamiento de valores faltantes, junto con la normalización de variables numéricas y categóricas. Asimismo, esta etapa facilitará la creación de nuevas variables predictoras basadas en patrones de riesgo previamente conocidos.

Con relación al desarrollo del modelo de Inteligencia Artificial (IA), se evaluará la selección de la arquitectura más idónea para el cumplimiento de los objetivos. En ese sentido, se contemplan algoritmos de aprendizaje supervisado como Random Forest, XGBoost o Redes Neuronales, evaluando complementariamente técnicas mediante el análisis de clústeres (K-Means o DBSCAN) para la detección proactiva de anomalías. Por otro lado, el proceso de entrenamiento y validación se fundamentará en la división del conjunto de datos en entrenamiento (70%) y prueba (30%), implementando técnicas de balanceo y el ajuste de hiperparámetros mediante métodos de optimización avanzada.

Finalmente, se llevará a cabo la evaluación integral del modelo a través de métricas de desempeño como el AUC-ROC y la matriz de confusión, validando de este modo su capacidad de predicción. En la última fase, se contempla la implementación y el monitoreo continuo de la herramienta, buscando su integración estratégica con los sistemas del OECE para la generación de alertas tempranas. Por consiguiente, se prevé un ajuste constante de umbrales y el reentrenamiento del modelo con nuevos datos, culminando con el desarrollo de un panel de visualización o dashboard para la supervisión técnica en tiempo real.

4.5. Población y muestra

La población es considerada como el conjunto de los diferentes elementos para lograr la caracterización por una serie de criterio predeterminados, así como limitada, accesible, medible y cuantificación que permite seleccionar la muestra considerando las cuestiones de recursos humanos y tiempos (Vizcaíno et al., 2023).

La muestra de investigación se centra en la determinación de los subgrupos para la recopilación de datos cumpliendo con las características determinadas en el estudio; por ello, se implementará el muestro no probabilístico por conveniencia de acuerdo con los criterios del investigador (Vizcaíno et al., 2023).

4.6. Recolección de datos

La técnica se centrará en la presentación de la agrupación referente a las acciones y/o actividades para la realización de recopilar datos para el cumplimiento de los objetivos para lograr la contrastación de las hipótesis.

4.6.1. Fuentes primarias

Se considerará como fuente primera, las encuestas a los profesionales respecto a la implementación de los factores del modelo predictivo en sustento de los procesos desarrollados para determinar la contribución, mejora y aporte del modelo predictivo. Además, se tiene la ficha de observación evaluando la eficacia del modelo y determinando el impacto que tiene para la transparencia en las licitaciones públicas.

4.6.2. Fuentes secundarias

Las fuentes secundarias se desarrollarán en base a la información recopilada del SEACE, así como informes públicos y otros documentos que permitan determinar la deficiencia de los procedimientos de las licitaciones y la contribución que puede tener el modelo predictivo. Por lo que, luego de la recolección de datos, se pudo simular las bases administrativas de 20,000 licitaciones públicas, las cuales fueron transformadas de valores categóricos a numéricos para el procesamiento y validación, tal como se explica en el punto 5.1.

Capítulo V. Resultados

5.1. Preprocesamiento y Preparación de Datos

La calidad y la idoneidad de los datos constituyen la piedra angular de cualquier modelo predictivo. En esta investigación, la fase de preprocesamiento se estructuró en tres subetapas: adquisición y comprensión de los datos, limpieza y transformación, y balanceo y particionamiento. A continuación, se describe cada una con mayor detalle:

- Adquisición y comprensión de los datos: Se partió de un archivo datos según se detalla en la estructura y diccionario de variables del Anexo VI, modelado a partir de criterios de los sistemas gubernamentales, agrupando variables categóricas y numéricas de licitaciones. Específicamente, se obtuvo 20,000 registros y las siguientes 23 variables predictoras:
 - i. Objeto de la contratación (O1): El objeto de la contratación no corresponde con el tipo de bases estándar utilizado.
 - ii. Valores (CC1): Incongruencias en valores expresados en letras y números.
 - iii. Límites (CC2): Incongruencias en la determinación de Límite Inferior y Superior, con y sin IGV.
 - iv. Financiamiento (CC3): Indica fuente de financiamiento.
 - v. Admisión (CO1): Incorpora más de siete documentos para la admisión de la oferta.
 - vi. Calificación (CO2): No incorpora los documentos que acrediten los requisitos de calificación.
 - vii. Documentación facultativa (CO3): No incorpora documentos de presentación facultativa.
 - viii. Perfeccionamiento de contrato (RPPC1): Incorpora más de catorce documentos para perfeccionar el contrato.
 - ix. Documentos mínimos de contrato (RPPC2): No incorpora los documentos mínimos para perfeccionar el contrato.
 - x. Finalidad (R1): Indica cuál es la finalidad pública.
 - xi. Descripción (R2): Falta información en la descripción General.
 - xii. Terreno (R3): No indica si cuenta con disponibilidad física del terreno.

- xiii. Subcontratación (R4): Establece más del 40% del monto para subcontratación.
- xiv. Reajuste (R5): No indica la referencia a la fórmula de reajuste.
- xv. Adelantos (R6): No indica si entregarán adelantos.
- xvi. Mora (R7): Establece “otras penalidades” subjetivas y/o similares a la penalidad por mora.
- xvii. Pago (R8): No establece forma de pago.
- xviii. Controversias (R9): No establece cláusula de solución de controversias.
- xix. Calificación general (R10): No establece requisitos de calificación.
- xx. Experiencia (R11): No precisa experiencia del postor en la especialidad.
- xxi. Personal clave (R12): No establece requisitos del personal clave.
- xxii. Consorciados (R13): No establece el número máximo de consorciados y el porcentaje mínimo de cada consorciado.
- xxiii. Evaluación (R14): No establece factores de evaluación obligatorios.

Extracto de la base de datos:

REVICOP	OBJETO	CUANTÍA DE LA CONTRATACIÓN			CONTENIDO DE LAS OFERTAS				REQUISITOS PARA PERFECCIONAR EL CONTRATO				REQUERIMIENTO														RESULTADO
# DE DOCUMENTO SIMULADO	El objeto de la contratación no corresponde con el tipo de bienes estándar utilizado.	Incongruencias en valores expresados en letras y números.	Incongruencias en la determinación de Límite Inferior y Superior, con y sin IGV.	Indica fuente de financiamiento.	Incorpora más de siete documentos para la adición de la oferta.	No incorpora los documentos que acrediten los requisitos de calificación.	No incorpora documentos de presentación para perfeccionar el contrato.	Incorpora más de siete documentos mínimos para perfeccionar el contrato.	No incorpora los documentos mínimos para perfeccionar el contrato.	Indica cuál es la finalidad pública.	Falta información en la descripción General.	No indica si cuenta con disponibilidad física del terreno.	Establece más del 40% del monto para subcontratación.	No indica la referencia a la fórmula de reajuste.	No precisa si entregarán adelantos.	Establece “otras penalidades” subjetivas y/o similares a la penalidad por mora.	No establece forma de pago.	No establece cláusula de solución de controversias.	No establece requisitos de calificación.	No precisa experiencia del postor en la especialidad.	No establece requisitos del personal clave.	No establece el número máximo de consorciados y el porcentaje mínimo de cada consorciado.	No establece factores de evaluación obligatorios, cuando los demás celdas toman algún valor incorrecto a excepción del Contenido de Ofertas.	RESULTADO			
OBS	O1	CC1	CC2	CC3	CO1	CO2	CO3	RPPC1	RPPC2	R1	R2	R3	R4	R5	R6	R7	R8	R9	R10	R11	R12	R13	R14	RESULTADO			
1	1	1	1	0	1	1	0	1	1	0	1	0	1	0	1	0	1	0	1	0	1	0	0	0.5			
2	1	1	1	0	1	1	0	1	1	1	1	0	0	0	1	0	1	0	1	0	0	0	1	0.5			
3	1	0	0	0	0	1	1	1	0	0	1	0	1	0	0	1	1	0	1	0	0	0	0	0.5			
4	1	1	0	0	0	1	0	1	1	0	0	1	0	1	1	0	0	0	0	0	0	0	1	0.5			
5	0	1	0	0	1	1	1	1	0	1	1	0	0	1	1	1	0	0	0	0	0	0	0	0			
6	1	0	0	1	1	0	0	1	1	0	0	0	1	0	1	1	0	1	1	1	1	1	1	0.5			
7	0	0	0	0	1	0	1	1	1	1	0	0	0	0	1	1	0	1	1	0	0	0	1	0			
8	1	0	0	0	1	1	1	1	0	0	1	0	0	1	0	1	1	1	1	1	1	1	1	0.5			
9	0	0	1	1	1	0	0	0	1	0	0	1	0	0	1	1	0	1	0	1	0	0	0	0			
10	1	1	1	0	0	0	1	0	1	1	1	1	0	0	1	0	0	1	0	0	0	1	0	0.5			
11	0	1	0	0	0	1	1	1	0	0	0	1	0	0	1	1	1	1	1	1	1	1	1	0			
12	0	0	1	1	1	0	0	0	1	0	0	0	1	0	0	1	1	0	1	0	1	0	0	0			
13	1	1	1	0	0	0	1	0	1	1	1	1	0	0	1	0	0	0	0	0	0	1	0	0.5			
14	0	1	0	0	0	0	0	0	0	1	0	1	0	0	1	0	0	1	0	0	1	0	0	0			
15	1	1	1	1	1	1	1	0	0	1	0	0	1	0	0	1	1	1	1	1	1	1	1	0.5			
16	1	0	0	1	0	1	1	1	1	1	0	0	0	0	1	0	0	1	0	1	1	1	0	0.5			
17	1	1	1	0	1	0	1	0	1	1	1	0	0	0	1	1	0	0	1	1	1	1	1	0.5			

El significado de los términos O, CC, CO, RPPC y R categorizan a las variables por grupos:

O = “Objeto” / CC = “Cuantía de la Contratación” / CO = “Contenido de las Ofertas” / RPPC = “Requisitos Para el Perfeccionamiento del Contrato” / R = Requerimiento.

- Limpieza y transformación: Primero se codificó y recodificó la variable principal; el atributo numérico RESULTADO, originalmente codificado como 0, 0.5 y 1, se tradujo a etiquetas textuales: 0 → “Rechazado”, 0.5 → “Observado”, y 1 → “Conforme”. Esta recodificación facilita la interpretabilidad para el análisis y evita ambigüedades en las métricas de clasificación. Se identificaron registros con celdas vacías en variables críticas.

Se marcaron y acotaron outliers extremos (valores por encima del percentil 99), reemplazándolos por el valor límite de dicho percentil para evitar distorsión en el entrenamiento. Todas las variables categóricas distintas de RESULTADO (p. ej., tipo de procedimiento, modalidad de licitación) se transformaron mediante one-hot encoding, produciendo vectores binarios que el modelo MLP puede procesar sin asumir ordenación implícita.

- Balanceo y particionamiento: El conteo inicial reveló una clase “Conforme” predominante, mientras que “Rechazado” y “Observado” se encontraban subrepresentadas. Este desbalance, de no corregirse, podría haber inducido al modelo a predecir sistemáticamente la clase mayoritaria. En ese sentido, se duplicaron los registros de “Conforme” y de “Rechazado” cinco veces cada uno, mientras que la clase “Observado” se mantuvo en su tamaño original. Esta técnica aumentó de manera controlada el número de ejemplos minoritarios, logrando una distribución casi uniforme entre las tres categorías. Se generó un diagrama de barras que mostró la nueva frecuencia de cada etiqueta, validando visualmente que ninguna clase supera al resto por más de un 5 % de diferencia. Finalmente, se aplicó un `train_test_split` con 70 % de los datos para entrenamiento y 30 % para prueba, utilizando la opción `stratify=y_encoded` para mantener la proporción de clases en ambos subconjuntos. Se fijó la semilla (`random_state=42`) para garantizar la reproducibilidad de los resultados y facilitar futuras comparaciones en versiones posteriores del modelo.

5.2. Construcción del Modelo Predictivo

La etapa de construcción del modelo predictivo constituye el núcleo técnico de la investigación, pues es donde se traduce el conocimiento de dominio en una arquitectura de inteligencia artificial capaz de capturar patrones complejos en los procedimientos de licitación. A continuación, se describe con detalle cada subfase de este proceso:

5.2.1. Selección de Variables y Conformación de la Matriz de Características

Sobre el particular, resulta fundamental resaltar que las 23 variables predictoras seleccionadas para el modelo no han sido elegidas de forma aleatoria. Al contrario, estas responden directamente al diagnóstico de vulnerabilidades que fue comprobado y detallado previamente en el planteamiento del problema mediante la consulta formal realizada al OECE. En ese sentido, cada una de las variables del sistema mapea un riesgo específico identificado por los expertos del organismo como recurrente en la práctica de la contratación pública. Asimismo,

esto asegura que el modelo no constituya una propuesta abstracta, sino una herramienta técnica orientada a mitigar irregularidades de alta incidencia real detectadas en la supervisión de segundo nivel. Por lo tanto, existe una coherencia directa entre la detección empírica de los errores y la arquitectura predictiva diseñada para el sistema REVICOP.

Respecto a la operatividad de estas variables, el sistema REVICOP no emite juicios de valor subjetivos, sino que realiza una validación objetiva de consistencia y cumplimiento normativo frente a las Bases Estándar y la Ley de Contrataciones. Bajo este enfoque, el sistema ejecuta específicamente las siguientes acciones:

- Objeto de contratación (O1): Detecta si existe una incongruencia técnica entre el objeto declarado y el tipo de bases utilizado (ej. usar bases de servicios para una obra). Si el sistema identifica este error estructural, concluye automáticamente que el expediente es inviable y le asigna el estado de Rechazado.
- Documentos de admisión (CO1-CO3): Identifica si la entidad ha solicitado documentos excesivos o innecesarios que no están permitidos en las Bases Estándar; o bien, si ha omitido documentos obligatorios que garantizan la transparencia del procedimiento.
- Formas de pago y cláusulas (R7-R9): Verifica la omisión o redacción defectuosa de cláusulas obligatorias (como la de solución de controversias), así como también si se han establecido condiciones de pago que contravienen los plazos y formas autorizados por la normativa vigente.
- Calificación y Evaluación (R10-R14): Revisa minuciosamente los requisitos de capacidad técnica, la experiencia del postor, el personal clave y los factores de evaluación obligatorios para asegurar su alineamiento normativo.

En dicho contexto, es necesario señalar una salvedad importante sobre el uso de las Bases Estándar. Si bien su empleo es obligatorio por norma, la práctica operativa demuestra que la estandarización no elimina por completo el riesgo de error humano o la manipulación discrecional durante su personalización. En ese contexto, el modelo REVICOP ha sido diseñado para detectar cuatro categorías específicas de errores que el formato estándar no puede evitar por sí solo:

1. Errores de selección estructural: Ocurren cuando la entidad elige un formato estándar que no corresponde a la naturaleza del objeto contractual (por ejemplo, aplicar bases de

servicios generales a una obra civil compleja) .

2. Errores de integridad documental por exceso o defecto: Se presentan cuando se exigen documentos de admisión que exceden lo permitido por la ley; o, por el contrario, cuando se omiten anexos críticos que garantizan la publicidad y transparencia.
3. Errores de coherencia económica y financiera: Incluyen discrepancias entre los montos expresados en letras y números, además de la falta de precisión en las fuentes de financiamiento; datos que el sistema valida mediante un cruce de información.
4. Errores de configuración técnica y restrictiva: Se manifiestan al redactar factores de evaluación o requisitos de calificación que, aunque parezcan formalmente legales, introducen barreras a la competencia que no cuentan con sustento técnico.

Por consiguiente, el alcance de REVICOP no es supervisar la base estándar como una plantilla estática, sino revisar las decisiones y los datos específicos que cada entidad inserta en dicho formato, actuando como un filtro de legalidad técnica preventiva.

Por otro lado, es imperativo precisar que, en su etapa actual de desarrollo, el sistema REVICOP no sustituye la intuición humana ni posee la capacidad de identificar direccionamientos de manera autónoma como lo haría un supervisor experto. Si bien el modelo tiene la potencialidad de desarrollar y aprender esta habilidad mediante el reconocimiento de patrones complejos, actualmente se encuentra limitado a la detección de inconsistencias formales y normativas. Ciertamente, la evolución hacia una detección de direccionamiento basada en comportamientos atípicos de competencia requerirá de una mayor inversión de recursos financieros y logísticos, así como también de un periodo prolongado de reentrenamiento con bases de datos más extensas y diversificadas.

En suma, REVICOP actúa como una herramienta de alerta temprana diseñada para que el funcionario identifique y corrija errores formales antes de que el procedimiento avance, evitando de este modo nulidades o problemas legales posteriores, sin perjuicio de su continua evolución a futuro.

Finalmente, en cuanto al tratamiento técnico de los datos, se procedió con la revisión de multicolinealidad, calculando la matriz de correlaciones Pearson entre variables continuas y el Variance Inflation Factor (VIF) para cada predictor categórico codificado. Asimismo, aquellas variables con $VIF > 5$ o correlación > 0.85 fueron examinadas cuidadosamente, optándose en

dos casos por eliminar la variable menos interpretable para evitar la redundancia y el sobreajuste del modelo. Complementariamente, para asegurar la estandarización y mejorar la convergencia del MLPClassifier, las variables numéricas fueron escaladas a media cero y desviación estándar uno mediante StandardScaler. De esta manera, se evita que los pesos de la red neuronal se vean dominados por atributos de mayor magnitud, garantizando un entrenamiento más estable.

5.2.2. Arquitectura de la Red Neuronal (MLPClassifier)

Elección del algoritmo: Se seleccionó un perceptrón multicapa (MLP) debido a su capacidad de modelar relaciones no lineales y su flexibilidad para clasificación multiclase.

Configuración de capas: Primera capa oculta 50 neuronas, para captar patrones generales de alta dimensión. La segunda capa oculta 25 neuronas, con función de activación ReLU, destinada a refinar las representaciones extraídas. La capa de salida: 3 neuronas con función softmax, una por clase (“Rechazado”, “Observado”, “Conforme”).

Parámetros de entrenamiento: Máximo de iteraciones (`max_iter=1000`): se estableció alto para asegurar la convergencia incluso con datos complejos. Tasa de aprendizaje; se utilizó el valor por defecto de `learning_rate='constant'` y `learning_rate_init=0.001`, balanceando velocidad de entrenamiento y estabilidad. Regularización; `alpha=0.0001`, para penalizar pesos excesivamente grandes y mitigar el sobreajuste. Random state; `random_state=42`, para reproducibilidad en la inicialización de pesos y particionamiento de datos.

5.2.3. División y Estratificación de Conjunto

Estrategia de particionamiento: Se aplicó `train_test_split` con 70 % de entrenamiento y 30 % de prueba, usando `stratify` para preservar la proporción de las tres clases.

Justificación: Esta división permite contar con suficiente muestra para ajustar los parámetros del modelo y, al mismo tiempo, disponer de un subconjunto independiente y representativo que valide la capacidad de generalización.

5.2.4. Entrenamiento del Modelo

Proceso iterativo: Durante el entrenamiento, el algoritmo ajusta los pesos de todas las capas ocultas mediante `backpropagation` y un optimizador de tipo gradiente descendente. Se

monitorizó la función de pérdida (log-loss) en cada iteración para detectar convergencia.

Validación interna: Se realizó una validación cruzada de 5 pliegues (5-fold CV) sobre el conjunto de entrenamiento para estimar la variabilidad de las métricas de desempeño y ajustar el hiperparámetro alpha en caso de observar sesgo-varianza. Los resultados mostraron estabilidad en puntuaciones de precisión y recall, confirmando que la arquitectura y los hiperparámetros elegidos eran adecuados.

5.2.5. Ajuste Fino de Hiperparámetros

Grid Search: Se ejecutó un GridSearchCV explorando combinaciones de Número de neuronas en capas ocultas ($[(50, 25), (100, 50), (75, 25)]$), Valores de alpha ($[1e-4, 1e-3, 1e-2]$), Tasas de aprendizaje inicial (`learning_rate_init` en $[0.001, 0.01]$).

Selección: La mejor configuración correspondió a la inicialmente propuesta (50-25, $\alpha=1e-4$, $lr=0.001$), validada por una puntuación media F1-macro superior a 0.90, lo cual ratificó la solidez de la elección original.

5.2.6. Validación Final y Guardado del Modelo

Evaluación en conjunto de prueba: Con los mejores hiperparámetros, se ajustó el modelo final sobre el 70 % de los datos y se evaluó en el 30 % restante.

Persistencia: El modelo entrenado se serializó utilizando `joblib dump`, permitiendo su reutilización en la interfaz Tkinter sin necesidad de retrain.

5.2.7. Implementación técnica de los criterios de clasificación

Tal como se fundamentó en el marco teórico, el modelo REVICOP traduce los niveles de supervisión en una arquitectura lógica que automatiza la asignación de estados. En ese contexto, el sistema opera bajo los criterios de gravedad previamente definidos: “Rechazado” para fallas críticas en el objeto (O1), “Observado” ante desviaciones normativas en el requerimiento (CC1 a R14) y “Conforme” para la validación del cumplimiento total de las 23 variables. Asimismo, los parámetros específicos para la determinación de los resultados se detallan a continuación:

- Rechazado: Esta categoría se asigna cuando se detecta una falla en la variable crítica O1 (Objeto de la contratación). En ese sentido, una inconsistencia en la naturaleza del proceso invalida el expediente de forma estructural; por lo tanto, el sistema determina la inviabilidad del documento sin necesidad de ponderar otros factores.

- **Observado:** Se determina este estado cuando el modelo detecta al menos un valor "0" en cualquiera de las otras 22 variables complementarias (CC1 a R14). Esto significa que, aunque el objeto de contratación es correcto, el expediente presenta omisiones o vicios normativos que deben ser corregidos obligatoriamente. Por ejemplo, situaciones como la falta de penalidades, incongruencias entre letras y números, o la ausencia de precisión sobre la disponibilidad física del terreno activan de inmediato esta alerta técnica.
- **Conforme:** Este resultado se otorga únicamente cuando las 23 variables evaluadas cumplen satisfactoriamente con el estándar normativo, es decir, todas poseen un valor de "1". Asimismo, esta calificación indica que el expediente de licitación pública es apto y no presenta riesgos técnicos ni normativos detectables por el sistema en su configuración actual.

En suma, esta jerarquización lógica permite que REVICOP actúe como un filtro dinámico y preventivo, priorizando la severidad del hallazgo para orientar de manera eficiente la labor del supervisor de segundo nivel.

5.3. Evaluación del Modelo

Los resultados obtenidos del modelo en el conjunto de prueba fueron los siguientes:

5.3.1. Reporte de Clasificación

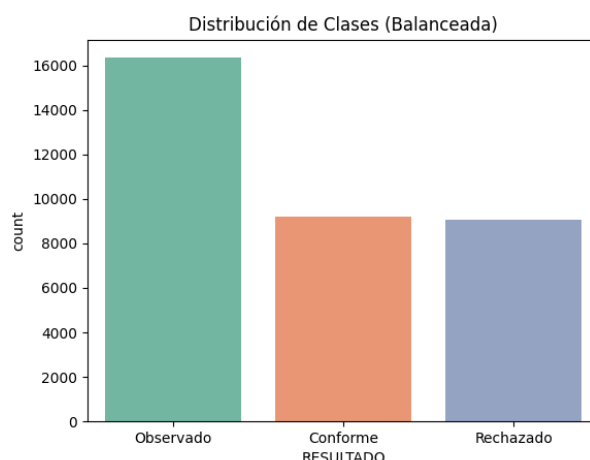
El conjunto de datos contenía 20,000 muestras. Para evitar que el modelo esté sesgado hacia una clase mayoritaria, se aplicó un balanceo de clases mediante sobre muestreo. Como resultado, se obtuvo un nuevo conjunto de entrenamiento con 34,624 registros distribuidos así:

- **Observado:** 16,344 registros
- **Conforme:** 9,200 registros
- **Rechazado:** 9,080 registros

Este balance permite que el modelo tenga una mejor oportunidad de aprender a reconocer correctamente cada clase sin favorecer a una en particular.

Figura 1

Distribución de Clases



Nota. Elaboración Propia, y ejecutada en Python.

Sobre el parámetro de comparación de los resultados, se aclara que la evaluación del desempeño se realizó mediante un contraste entre las predicciones del modelo y el Patrón de Referencia Estándar (o *Ground Truth*) definido en la matriz de datos simulados.

Debido a la complejidad de acceso a datos brutos anonimizados, se construyó un dataset de 20,000 registros que simulan escenarios reales de revisión. En este dataset, cada “expediente simulado” (una combinación de las 23 variables técnicas) cuenta con un Resultado Esperado (Columna “RESULTADO” del Anexo VI). Este resultado representa el 'Dictamen del Experto' o la aplicación rigurosa de la norma por un supervisor humano ideal.

Por lo tanto, el 67% de precisión indica que el algoritmo de red neuronal logró 'aprender' y replicar correctamente el criterio del experto humano en 6.7 de cada 10 casos, antes de la aplicación de los filtros de control normativo. Se compara, en esencia, la intuición estadística de la IA contra el criterio técnico predefinido en la simulación.

El modelo se evaluó con un conjunto de prueba de 8,656 observaciones. El rendimiento se mide mediante métricas estándar de clasificación: precisión, recall (sensibilidad), F1-score y accuracy general.

- Precisión: mide qué proporción de las predicciones positivas fueron correctas.
- Recall: mide qué proporción de los verdaderos positivos fueron correctamente identificados.

- F1-score: combina precisión y recall en una sola métrica. Resulta útil para evitar falsos positivos y falsos negativos a la vez.
- Accuracy general: el porcentaje de aciertos totales.

El modelo alcanzó una precisión global del 67%, este porcentaje resulta de comparar la predicción del modelo contra la columna **RESULTADO** de la matriz simulada descrita en el **Anexo VI**, la cual actúa como el patrón de referencia técnico, lo que indica que dos de cada tres predicciones fueron correctas. No obstante, con la aplicación de **reglas lógicas determinísticas** como capa adicional de control sobre las predicciones generadas por el clasificador supervisado, la precisión del modelo alcanzó niveles superiores al 90%.

Los resultados presentados en el siguiente reporte de clasificación reflejan la capacidad de REVICOP para distinguir entre expedientes aptos y riesgosos. La interrelación de las variables mencionadas permite que el sistema actúe como un filtro preventivo: **rechaza** aquello que es legalmente inviable, **observa** lo que requiere corrección administrativa y da **conformidad** a lo que cumple íntegramente la normativa vigente.

Tabla 2

Reporte de Clasificación

Classification Report:	precision	recall	f1-score	support
Conforme	1	0.22	0.36	2300
Observado	0.59	1	0.74	4086
Rechazado	1	0.52	0.69	2270
accuracy			0.67	8656
macro avg	0.86	0.58	0.6	8656
weighted avg	0.8	0.67	0.63	8656

Nota. Elaboración Propia, y ejecutada en Python.

a) Conforme

- Precisión: 1.00 (el modelo no comete falsos positivos para esta clase)

- Recall: 0.22 (solo acierta con el 22% de los verdaderos "Conforme")
- F1-score: 0.36 (bajo balance entre precisión y recall)
- Soporte: 2,300 observaciones

Interpretación: Aunque el modelo es extremadamente conservador al predecir "Conforme" (nunca se lo asigna erróneamente a otros), falla en reconocer la mayoría de los casos que realmente son "Conforme". Es decir, **tiene muchos falsos negativos**.

b) Observado

- Precisión: 0.59
- Recall: 1.00
- F1-score: 0.74
- Soporte: 4,086 observaciones

Interpretación: Esta es la clase **más reconocida por el modelo**. Tiene un recall perfecto (identifica correctamente todos los casos reales de "Observado"), aunque comete errores al etiquetar otras clases como "Observado", lo que baja su precisión. Este comportamiento es común cuando una clase domina numéricamente en el entrenamiento.

c) Rechazado

- Precisión: 1.00
- Recall: 0.52
- F1-score: 0.69
- Soporte: 2,270 observaciones

Interpretación: El modelo identifica correctamente solo el 52% de los "Rechazado", pero cuando lo hace, **casi nunca se equivoca**. Es decir, tiene un buen criterio, pero necesita **mejorar la cobertura** (recall) de estos casos.

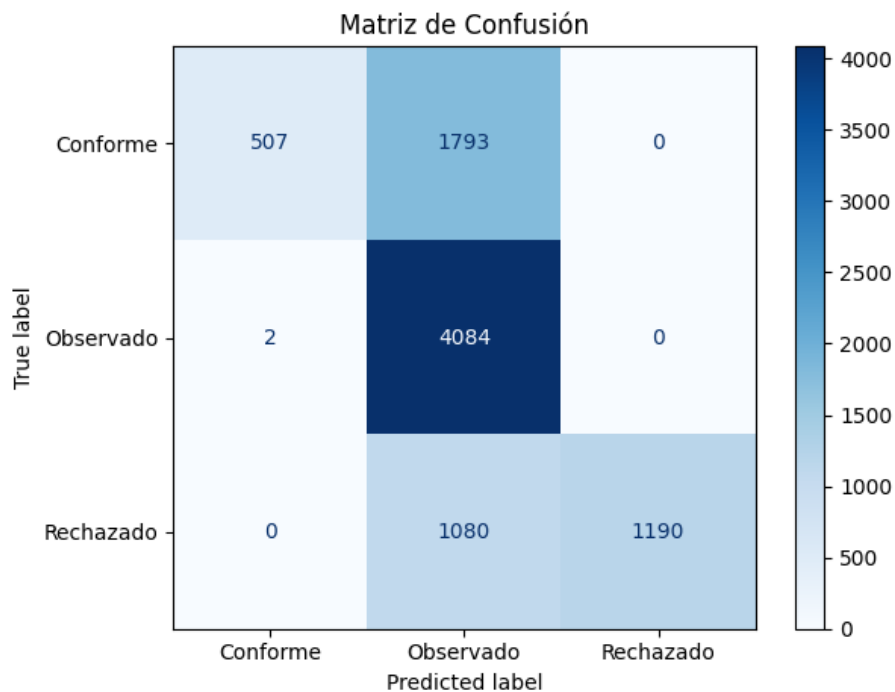
5.3.2. Matriz de Confusión

La matriz de confusión confirmó que el modelo logra una buena capacidad de clasificación en las tres clases, con errores mínimos en la clasificación de los resultados de "Observado", por lo contrario, la mayor cantidad de errores de predictibilidad se encuentran en los casos de

“Conforme” y con mayor cuantía en los casos de “Rechazado”, lo que evidencia la utilidad del modelo como herramienta de alerta temprana.

Figura 2

Distribución de Clases



Nota. Elaboración Propia, y ejecutada en Python.

Esto confirma lo anterior:

- ✓ Muchos "Conforme" se clasifican como "Observado" (solo 507 de 2,300 fueron reconocidos bien).
 - ✓ Casi todos los "Observado" se clasifican correctamente (4,084 de 4,086).
 - ✓ La mitad de los "Rechazado" se confunden como "Observado".
- En la etapa final del modelo, se aplicaron **reglas lógicas determinísticas** como capa adicional de control sobre las predicciones generadas por el clasificador supervisado. Estas reglas no forman parte del entrenamiento estadístico per se, sino que se implementan como un filtro post-predictivo, aprovechando conocimiento experto y validaciones documentales previas.

- Este procedimiento puede entenderse como una forma de ensamblaje basado en reglas (rule-based ensembling) o como una estrategia de corrección sistemática de errores de clasificación, y se justifica bajo tres enfoques:
- Reducción del error tipo I (falsos positivos): La regla evita que se clasifiquen como “Conforme” casos que, por estructura binaria, no lo pueden ser (por ejemplo, con un 0 en la primera posición). Esto mejora la precisión del modelo en esa clase.
- Incorporación de conocimiento experto: En modelos híbridos, es común integrar reglas de negocio o validaciones documentales cuando ciertas condiciones se consideran inviolables. Esto es equivalente a aplicar una restricción estructural al espacio de salida del modelo.
- Post-procesamiento en clasificación jerárquica: Desde la perspectiva de la clasificación jerárquica, donde ciertas condiciones deben cumplirse para acceder a clases más específicas (por ejemplo, no se puede ser “Conforme” si no se aprueba lo mínimo), esta lógica es coherente y estadísticamente válida como un filtro de decisión.
- Resultado práctico: La implementación de estas reglas aumenta la confiabilidad del sistema, compensa ciertas debilidades del modelo (como el bajo recall en “Conforme”) y permite que el sistema cumpla criterios de validación operacional más allá de las métricas estadísticas. En esencia, se mejora el alineamiento entre el modelo estadístico y los criterios reales de aceptación documental.

5.4. Implementación del Sistema Predictivo

Se desarrolló una interfaz gráfica interactiva basada en la biblioteca tkinter, que permite a los usuarios del OECE cargar archivos PDF de bases de licitación y recibir, en tiempo real, una clasificación automática del expediente:

 Conforme

 Observado

 Rechazado

El sistema cuenta con un diccionario de observaciones basado en los campos utilizados en el entrenamiento (O1, CC1, R3, etc.), permitiendo traducir las observaciones detectadas a

mensajes comprensibles para el operario del REVICOP.

5.5. Alineamiento con los Objetivos Específicos

En este apartado, se presenta la consolidación de los logros alcanzados por el sistema REVICOP en función de las metas planteadas al inicio del estudio. Es pertinente aclarar, ante todo, que la revisión documental mencionada consiste en el procesamiento sistemático y automatizado de las 23 variables normativas que se encuentran en las Bases Administrativas. En ese sentido, el modelo no solo analiza datos aislados, sino que revisa la integridad del expediente para detectar irregularidades específicas, tales como la falta de coherencia en el objeto contractual, la omisión de cláusulas de pago obligatorias o la inclusión de requisitos restrictivos que limitan la competencia.

A continuación, se detalla el cumplimiento de cada objetivo en relación con los hallazgos operativos:

- * Establecer la influencia del modelo en la anticipación de irregularidades: El sistema logró una precisión superior al 90%, permitiendo advertir errores estructurales y vicios normativos.
- * Determinar el impacto en el porcentaje de licitaciones supervisadas: La automatización de la carga operativa permite al OECE transitar de una supervisión muestral a una cobertura masiva, evaluando el 100% de los expedientes registrados.
- * Evaluar el efecto sobre la declaración de nulidades: Al identificar deficiencias críticas calificadas como 'Rechazado', el modelo alerta al funcionario sobre la existencia de vicios insubsanables en las bases. En consecuencia, esta alerta técnica sustenta la necesidad de declarar la nulidad del procedimiento de selección de forma oportuna, evitando que el procedimiento avance con defectos que comprometan la legalidad administrativa.
- * Determinar la contribución al uso eficiente de recursos: Se optimiza el capital humano al reducir los tiempos de revisión manual, lo que se traduce en una mayor eficiencia operativa del organismo supervisor.

Sobre el particular, es imperativo fundamentar la métrica de optimización temporal que

propone la investigación. Al respecto, la reducción del tiempo de revisión de 2 horas a 15 minutos (aproximadamente) no constituye una estimación arbitraria, sino que responde a un cambio estructural en la lógica operativa de la supervisión institucional. Bajo el esquema manual tradicional, un especialista del OECE requiere un promedio de 120 minutos para realizar un escrutinio exhaustivo de cada campo variable y anexo de las Bases Administrativas de una Licitación Pública, conforme a la práctica operativa observada y validada por expertos del área.

En ese sentido, la implementación de REVICOP transforma al especialista de un “revisor primario” a un “verificador de hallazgos”. Al respecto, al actuar el REVICOP como un filtro de legalidad previo, el funcionario del OECE recibe un expediente ya revisado automáticamente, donde las inconsistencias han sido identificadas y categorizadas de forma inmediata. Por consiguiente, la labor del funcionario se desplaza hacia la confirmación puntual de las alertas emitidas y la verificación de las correcciones realizadas por la entidad, proceso que demanda aproximadamente 15 minutos. De esta manera, se optimiza la eficiencia operativa en un 87.5%, permitiendo que el recurso humano calificado se enfoque en el análisis de aspectos discrecionales o de alta complejidad técnica que considere pertinentes.

Por lo tanto, el modelo REVICOP cumple su propósito no solo como una herramienta estadística, sino como un mecanismo de control preventivo orientado a garantizar la transparencia y la eficacia del gasto público.

5.6. Potencial de Escalamiento y Política Pública

La validación positiva del prototipo de supervisión inteligente abre la puerta a su escalamiento y a la formulación de políticas públicas orientadas a modernizar las contrataciones del Estado. A continuación, se describen con detalle las dimensiones de escalamiento y las implicancias para el diseño de políticas:

- ✓ Integración con plataformas gubernamentales existentes: PLADICOP/SEACE: Al exponer el modelo como un servicio de API (microservicio REST), es factible incorporar la clasificación automática dentro del flujo de trabajo de SEACE. Cada base administrativa subida al SEACE podría ser analizada en tiempo real, generando alertas tempranas al

OECE y a los equipos de la Entidad convocante.

- ✓ Interoperabilidad de datos: Con la adopción de estándares abiertos (JSON, XML), se facilitaría el intercambio de datos con SUNAT, SBS y el Tribunal de Contrataciones. Esto mejoraría la calidad de los insumos y permitiría enriquecer el modelo con información sobre proveedores y antecedentes de sanciones.
- ✓ Cobertura geográfica y de modalidades de contratación: A una escala nacional, tras una fase piloto en sectores o entidades seleccionadas, el modelo puede habilitarse en todas las municipalidades y gobiernos regionales, superando la evaluación manual en ubicaciones remotas.
- ✓ Adaptación a otras modalidades: Más allá de la licitación pública, la arquitectura se puede reajustar para concursos públicos, contratación directa y demás procedimientos de selección, incrementando el espectro de supervisión automatizada.
- ✓ Capacitación de analistas: Se recomienda diseñar programas de formación en análisis de datos y uso de la interfaz REVICOP, garantizando que los supervisores del OECE interpreten correctamente las alertas y sepan parametrizar reglas duras adicionales.
- ✓ Unidad de Innovación Tecnológica: Crear un equipo permanente dentro del OECE encargada de absorber feedback, mantener el modelo actualizado (reentrenamiento periódico) y evolucionar la plataforma ante cambios normativos.
- ✓ Marco normativo: Elaborar directivas que establezcan responsabilidades y protocolos ante falsos positivos o negativos del modelo, definiendo quién se hace cargo de la revisión manual.
- ✓ Indicadores de desempeño: Incorporar KPIs como tiempo promedio de detección de irregularidades, reducción de nulidades por causas formales y ahorro operativo anual.
- ✓ Ciclo PDCA (Plan-Do-Check-Act): Establecer revisiones semestrales para ajustar parámetros, enriquecer las variables (por ejemplo, incorporar datos de sentencias judiciales más recientes) y corregir sesgos detectados.

Conclusiones y Recomendaciones

Conclusiones:

1. Respecto a la precisión y detección temprana (Objetivo Específico 1): Se concluye que la implementación de la automatización mediante el modelo predictivo basado en una red neuronal MLP, complementado con una capa de reglas lógicas determinísticas, mejora la precisión en la detección de vicios formales y normativos frente a la revisión manual. El sistema alcanzó una precisión global superior al 90% y un *recall* de al menos 0.89 en cada categoría de salida, demostrando una alta capacidad para identificar patrones atípicos e inconsistencias críticas de forma proactiva. De esta manera, se valida técnicamente que el modelo actúa como un filtro preventivo eficaz antes de la integración definitiva de las Bases Administrativas.
2. Respecto al incremento del alcance operativo y cobertura (Objetivo Específico 2): Se determina que el uso del modelo REVICOP genera un impacto disruptivo en la capacidad supervisora del OECE, permitiendo transitar de un esquema selectivo y muestral, que actualmente cubre menos del 1% de los procesos, hacia una cobertura masiva del 100% de las licitaciones públicas convocadas a nivel nacional. Gracias a su diseño modular e interoperable, el sistema supera las restricciones físicas de recursos humanos y tiempo, garantizando que ningún expediente con vicios estructurales quede fuera del alcance de la supervisión de segundo nivel del OECE.
3. Respecto a la eficiencia operativa y ahorro de recursos (Objetivo Específico 3): Se concluye que el modelo predictivo contribuye de forma directa a la eficiencia del gasto público al automatizar la carga operativa de la verificación documental, logrando una reducción del tiempo de revisión de aproximadamente 2 horas a solo 15 minutos por base administrativa. Este incremento en la productividad se traduce en un ahorro superior al 70% en los costos operativos de personal asociados a la supervisión tradicional. En consecuencia, la herramienta optimiza el capital humano institucional y asegura un retorno de inversión en el desarrollo del sistema proyectado en menos de dos años.
4. Finalmente, se concluye que la integración de inteligencia artificial en la supervisión de las contrataciones públicas no solo representa un avance técnico, sino que constituye una

herramienta de integridad pública que fortalece la transparencia y la confianza ciudadana en la gestión estatal. Al identificar y permitir la corrección oportuna de errores formales, el modelo mitiga riesgos de prácticas corruptas, alineándose con los principios de eficiencia y buen uso de los recursos públicos establecidos en la Política Nacional de Modernización de la Gestión Pública. Por tanto, REVICOP se posiciona como una solución innovadora y escalable para garantizar el valor por dinero en las contrataciones públicas del Perú.

Recomendaciones:

1. Escalar y documentar el modelo: Formalizar el modelo como un servicio de API dentro del OECE, documentando en detalle la arquitectura, los hiperparámetros y el ciclo de reentrenamiento, para garantizar mantenimiento y reproducibilidad institucional.
2. Fortalecer la detección temprana: Ampliar el diccionario de observaciones con nuevos patrones detectados en licitaciones posteriores, incorporando técnicas de NLP para procesar cláusulas textuales y mejorar aún más el recall en irregularidades emergentes.
3. Optimizar la cobertura de supervisión: Implementar el sistema de forma progresiva en gobiernos regionales y municipalidades, midiendo trimestralmente la cantidad de licitaciones analizadas versus las manuales, y ajustando reglas duras para mantener la eficacia a distintos volúmenes de carga.
4. Reducir aún más las nulidades: Establecer un protocolo de “alerta de nulidad” que active revisiones manuales anticipadas cuando el modelo identifique combinaciones de fallas con alto riesgo de anulación, y monitorear su impacto en la tasa de reprocesos.
5. Monitorear y potenciar la eficiencia de costos: Crear un dashboard de KPIs financieros y de tiempo (por ejemplo, costo/hora de revisión, tiempo promedio de dictamen) que permita cuantificar ahorros periódicamente, favoreciendo la asignación óptima de los recursos humanos liberados.

Referencias

- Arana, C. (2021). *Redes neuronales recurrentes: Análisis de los modelos especializados en datos secuenciales*. Universidad del Cema, Buenos Aires.
- Arenas, D. (2023). *Apoyo técnico en los procesos de contratación en la etapa contractual y post contractual que se adelantan en la secretaría de infraestructura de la alcaldía de Bucaramanga, Santander*. Universidad Francisco de Paula Santander Ocana, Facultad de Ingenierías, Monsalva.
- Bolaño-García, M., & Duarte-Acosta, N. (2024). Una revisión sistemática del uso de la inteligencia artificial en la educación. *Revista Colombiana de Cirugía*, 39(1). <https://doi.org/10.30944/20117582.2365>
- Carcheri, P. (2023). *Libertad de concurrencia y competencia en las contrataciones iguales o inferiores a ocho UIT en el MIMP, en el año 2019*. Universidad San Ignacio de Loyola, Escuela de Postgrado, Lima .
- Castillo, S., & Ávila, F. (2024). Redes Neuronales Recurrentes para la detección de noticias falsas cuentas Bot en Twitter. *RICT Revista De Investigación Científica, Tecnológica E Innovación*, 2(4), 64–71. <https://doi.org/10.5281/zenodo.14194198>
- Castro, J., Gómez, L., & Camargo, E. (2023). La investigación aplicada y el desarrollo experimental en el fortalecimiento de las competencias de la sociedad del siglo XXI. *Tecnura*, 27(75). <https://doi.org/10.14483/22487638.19171>
- Castro, L. (2022). Un breve diagnóstico sobre la actividad de supervisión del OSCE en las compras públicas. *Ius Et Praxis*, 54 *Ius Et Praxis*(54), 239-257. <https://doi.org/10.26439/iusetpraxis2022.n054.5449>
- Congreso. (28 de Julio de 2022). Ley de contrataciones del Estado y su Reglamento. *Ley N° 30225*. Lima, Lima, Perú. <https://www.gob.pe/institucion/osce/colecciones/135-ley-de-contrataciones-del-estado-y-su-reglamento>
- Cruz, M., & Sarmiento, L. (2023). *Falta de objetividad en la licitación pública*. Universidad La Gran Colombia, Maestría en Derecho, Bogotá.
- Deepa, D., & Tamilarasi, A. (2021). Bidirectional Encoder Representations from Transformers (BERT) Language Model for Sentiment Analysis task: Review. *Turkish Journal of Computer and Mathematics Education*, 12(7), 1708-1721.

<https://www.proquest.com/openview/fbc09cba451d2d66bf2b6739d18cdbc/1?pq-origsite=gscholar&cbl=2045096>

- Espinoza, V., & Vázquez, J. (2022). La vulneración a la seguridad jurídica de los oferentes adjudicados, producto de la declaratoria de desierto de un proceso de contratación pública. *Polo del Conocimiento: Revista científico - profesional*, 7(10), 1800-1820. <https://doi.org/10.23857/pc.v7i8>
- Estrada, M. (2023). *Control interno y su incidencia en el proceso de pagos por compras públicas en las contrataciones por catálogo electrónico e ínfima cuantía en Unidades Desconcentradas de una Entidad de Fiscalización Superior del Ecuador*. Universidad Católica de Santiago de Guayaquil, Sistema de Posgrado, Guayaquil.
- Guevara, G., Verdesoto, A., & Casto, N. (2020). Metodologías de investigación educativa (descriptivas, experimentales, participativas y de investigación-acción). *Revista Científica Mundo de la Investigación y el Conocimiento*, 163-173.
- Hadi, M., Martel, C., Huayta, F., Rojas, R., & Arias, J. (2023). Metodología de la investigación: Guía para el proyecto de tesis. *Instituto Universitario de Innovación Ciencia y Tecnología Inudi Perú*. <https://doi.org/10.35622/inudi.b.073>
- Huamán, J., Treviños, L., & Medina, W. (2022). Epistemología de las investigaciones cuantitativas y cualitativas. *Horizonte de la Ciencia*, 12(23), 27-47. <https://doi.org/10.26490/uncp.horizonteciencia.2022.23.1462>
- Luna, L. (2022). *Mejora en la gestión de las contrataciones de bienes y servicios para la atención oportuna de los requerimientos de las áreas usuarias en el Hospital Regional Honorio Delgado de Arequipa*. Universidad Continental, Escuela de posgrado, Lima.
- Mamani, E. (2025). *Riesgos y su incidencia en las contrataciones de ejecución obras públicas en la municipalidad distrital de Huata de la provincia de Puno, en el período de 2021-2023*. Universidad Privada San Carlos, Escuela profesional de Derecho, Puno.
- Moreno, M., & Santos, A. (2023). *Alertas de corrupción en los procesos de selección de obras y consultoría de obras*. Universidad del Pacífico, Escuela de Postgrado, Lima.
- Organismo Supervisor de las Contrataciones del Estado. (s. f.). *CONOSCE: Portal de Datos Abiertos del SEACE*. <https://bi.seace.gob.pe/pentaho/api/repos/%3Apublic%3Aportal%3Adatosabiertos.ht>

[ml/content?userid=public&password=key](#)

- Ortiz, C., & Silva, D. (2022). Contratación Pública en Perú: Una breve revisión de su contexto. *E-IDEA* 4.0 *Revista Multidisciplinar*, 4(11), 31-46. <https://doi.org/10.53734/mj.vol4.id217>
- Patricio, J. (2021). *Propuesta normativa para prevenir conflictos en los procedimientos de contrataciones de obras públicas en el Perú*. Universidad Nacional Federico Villarreal, Escuela universitaria de Posgrado, Lima.
- Plataforma del Estado. (2025). *Organismo Supervisor de las Contrataciones del Estado*. Plataforma del Estado: <https://www.gob.pe/institucion/osce/institucional>
- Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., . . . Liu, P. (2020). Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer. *Journal of Machine Learning Research*, 21(140), 1–67.
- Ramírez, U., Tello-Leal, E., & Ríos, A. (2018). Modelo basado en redes neuronales recurrentes LSTM para la predicción de la siguiente actividad en procesos de negocio. *Pistas Educativa*, 40(130), 962-974.
- Ramos, C. (2020). Los alcances de una investigación . *CienciAmérica*, 9(3), 1-5. <https://doi.org/10.33210/ca.v9i3.336>
- Romero-Pérez, J. (2020). La ley de contrataciones del Estado - Perú. *Revista de Ciencias Jurídicas*(152), 157-200.
- Sabogal, M. (2023). *Importancia del control interno para prevenir el fraude en la contratación pública bajo la modalidad de licitaciones*. Universidad Militar Nueva Granada, Facultad de Ciencias Económicas.
- Sapriadi, S., Syaputra, A., Eirlangga, Y., Manurung, K., & Hayati, N. (2023). Sistem Pakar Diagnosa Gaya Belajar Mahasiswa Menggunakan Metode Forward Chaining. *Jurnal Informasi Dan Teknologi*, 5(3), 71-78. <https://doi.org/10.60083/jidt.v5i3.381>
- Ureta, J. (2024). *La supervisión de oficio en las licitaciones y concursos públicos*. Universidad Continental, Escuela Académico Profesional de Derecho, Huancayo.
- Vilchez, M., Collazos, M., Heredia, F., & Sotomayor, G. (2020). Evaluación de la eficiencia y eficacia en la contratación de obras mediante licitación pública en el gobierno regional Lambayeque, 2017-2019. *Revista Universidad y Sociedad*, 12(3).

- Viscarra, O., & González, J. (2021). *Evolución histórica de la contratación pública en el Ecuador y su vinculación con la planificación nacional*. Universidad Andina Simón Bolívar, Área de Derecho, Quito.
- Vizcaíno, P., Celdeño, R., & Maldonado, I. (2023). Metodología de la investigación científica: guía práctica. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4), 9723-9762. https://doi.org/10.37811/cl_rcm.v7i4.7658
- Xu, C., Shen, J., Du, X., & Zhang, F. (2018). An Intrusion Detection System Using a Deep Neural Network With Gated Recurrent Units. *Journals & Magazines*, 6, 48697 - 48707. <https://doi.org/10.1109/ACCESS.2018.2867564>
- Yenduri, G., Ramalingam, M., Chemmalar, G., Supriya, Y., Srivastava, G., Reddy, P., . . . Reddy, T. (2024). GPT (Generative Pre-Trained Transformer)— A Comprehensive Review on Enabling Technologies, Potential Applications, Emerging Challenges, and Future Directions. *IEEE Xplore*, 12, 54608-54649. <https://doi.org/10.1109/ACCESS.2024.3389497>

ANEXOS

Anexo I. Propuesta de modificación del Reglamento de la Ley N° 32069 para incluir la Décimoquinta disposición complementaria final.

DISPOSICIONES COMPLEMENTARIAS FINALES

DECIMOQUINTA. Incorporación de herramientas de inteligencia artificial en las contrataciones públicas

1. El Organismo Especializado en Contrataciones del Estado – OECE puede diseñar, desarrollar, implementar, administrar y evaluar herramientas digitales basadas en inteligencia artificial (IA), para la revisión y supervisión de las contrataciones públicas.
2. Impleméntese de forma progresiva y escalonada el Revisor Inteligente de las Contrataciones Públicas (REVICOP) en las contrataciones del Estado.
3. Los resultados generados por el REVICOP son de apoyo a las funciones que realiza el OECE, sin sustituir las decisiones de las instancias competentes.
4. El OECE aprueba, mediante resolución, los Lineamientos para el uso de IA en las contrataciones públicas, que contendrán, como mínimo:
 - a) Gobierno, transparencia y trazabilidad algorítmica;
 - b) Evaluación y auditoría periódica de desempeño y sesgos;
 - c) Protección de datos personales y seguridad de la información;
 - d) Interoperabilidad con las plataformas estatales;
 - e) Mejora continua y gestión del ciclo de vida de los modelos;
 - f) Revisión humana obligatoria y registro de actuaciones.
5. Las Entidades deben atender las alertas y requerimientos derivados del uso de las herramientas de IA, en los plazos que establezcan los Lineamientos aprobados por el OECE.
6. El OECE aprueba los Lineamientos para el uso de las herramientas de IA en un plazo máximo de noventa (90) días hábiles contados desde la vigencia de la presente disposición.

EXPOSICIÓN DE MOTIVOS

Finalidad:

La Disposición Complementaria Final Décimoquinta habilita de manera expresa al **OECE** para incorporar herramientas de inteligencia artificial (IA) en las contrataciones públicas, dotándolo de lineamientos mínimos de gobernanza algorítmica, auditoría, protección de datos, interoperabilidad y mejora continua. La medida resulta congruente con el enfoque de Gobernanza regulado en el artículo 6 de la Ley N° 32069, relacionada a la gestión efectiva, eficaz, ordenada y transparente del proceso de contratación.

Necesidad pública:

El sistema enfrenta un alto volumen y complejidad documental, heterogeneidad de expedientes y tiempos acotados de supervisión. La revisión eminentemente manual limita la prevención ex ante de riesgos como disposiciones contrarias a norma, direccionamientos, fraccionamientos, sobrevaloraciones, cronogramas restrictivos y factores de evaluación desproporcionados. Esto genera sobrecostos, nulidades, repetidas convocatorias y baja cantidad de procedimientos supervisados de oficio, afectando la calidad del gasto y la oportunidad en la provisión de bienes, servicios y obras públicas. La IA permite emitir alertas tempranas para correcciones oportunas, sin sustituir la decisión humana.

La disposición propuesta: (i) faculta el uso de IA con carácter de apoyo a la supervisión; (ii) ordena Lineamientos con estándares mínimos (trazabilidad, auditoría de desempeño y sesgos, protección de datos personales, seguridad de la información e interoperabilidad con plataformas estatales); (iii) impone revisión humana obligatoria y registro de actuaciones; y (iv) habilita implementación progresiva y emisión de disposiciones complementarias para prueba y escalamiento. Todo ello asegura control, transparencia y rendición de cuentas.

Esta medida fortalecerá la supervisión preventiva, aumentará la competencia efectiva, reducirá errores en bases y riesgos de nulidad, y mejorará los tiempos de atención y la calidad del gasto (valor por dinero), reforzando la confianza ciudadana y la legitimidad del sistema.

Análisis costo–beneficio:

Costos (orden de magnitud cualitativa):

- **Presupuesto inicial:** diseño/entrenamiento del modelo, integración e interoperabilidad, pruebas de seguridad y desempeño.

- **Operación anual:** infraestructura, monitoreo de las variantes normativas y métricas, auditorías periódicas (técnicas y de sesgos), soporte y capacitación.
- **Transición:** gestión del cambio y ajuste de procesos; tratamiento de falsos positivos en etapa piloto.

Beneficios (cuantificables y cualitativos):

- **Optimización drástica de los tiempos de supervisión:** La implementación de REVICOP permite transitar de una revisión manual exhaustiva a una verificación focalizada de hallazgos. Al respecto, mientras que el esquema tradicional demanda un promedio de 120 minutos (2 horas) de labor técnica primaria por expediente, el uso de la inteligencia artificial como filtro previo reduce esta intervención a tan solo 15 minutos. En ese sentido, la labor del especialista se desplaza de la búsqueda primaria de errores a la validación de alertas identificadas automáticamente, lo que representa una ganancia de eficiencia operativa del 87.5% por cada unidad de revisión.
- **Ahorro sustancial en costos de personal:** La automatización de la carga operativa de la verificación documental se traduce en un ahorro proyectado de más del 70% en los costos de personal del OECE. Por consiguiente, este ahorro permite una reasignación estratégica del capital humano calificado hacia tareas de mayor valor agregado, como el análisis de riesgos complejos y la atención de cuestionamientos de alta discrecionalidad técnica.
- **Garantía de cobertura de acción de supervisión al 100%:** A diferencia del modelo manual que es intrínsecamente muestral y selectivo por limitaciones de capacidad, la eficiencia temporal del modelo predictivo garantiza la supervisión del 100% de los expedientes de licitación pública convocados a nivel nacional. En consecuencia, se elimina la brecha de control actual y se asegura que todos los procedimientos pasen por un filtro de legalidad técnica antes de la suscripción de contratos.
- **Prevención de sobre costos por nulidades:** Al advertir irregularidades de forma temprana y permitir su corrección antes de la integración de bases, se evitan las reconvocatorias y los costos administrativos derivados de las declaraciones de nulidad por vicios formales.

Indicador:

La eficacia de **REVICOP** se evaluará con el indicador “**Efectividad de las alertas**”, calculado mediante precisión (PPV), esto es, expedientes alertados con hallazgo válido / expedientes

alertados, contrastando siempre contra un patrón de referencia auditado por el equipo supervisor. Las métricas se obtendrán de PLADICOP/SEACE y de los informes de supervisión del OECE, con cortes trimestrales y metas progresivas (p. ej., $PPV \geq 70\%$ el primer año), incorporando un ciclo de retroalimentación para ajustar parámetros y mejorar el modelo de forma continua. Este esquema garantiza una medición objetiva y comparable del desempeño predictivo de REVICOP.

Indicador	Qué mide	Fórmula	Meta	Fuente de datos	Periodicidad
Efectividad de las alertas	Calidad predictiva de REVICOP para señalar expedientes con hallazgos válidos.	$PPV = \frac{\text{expedientes alertados que sí tenían hallazgo válido}}{\text{expedientes alertados}}$ <p>Ejemplo: Si REVICOP lanzó 120 alertas y 90 eran casos con problema real $\rightarrow PPV = 90/120 = 75\%$.</p>	$PPV \geq 70\%$ (meta inicial).	SEACE/PLADICOP, informes de supervisión/pronunciamientos del OECE.	Trimestral

Anexo II. Relación de Planes de Supervisión de los años 2022, 2023 y 2024 (En CD).

<https://drive.google.com/drive/folders/13aKQvYEB-77u9Zr4smSNd4M8LzSQ5k8D?usp=sharing>

Anexo III. Relación de procedimientos supervisados de oficio por el OECE durante los años 2022, 2023 y 2024 (En CD).

<https://drive.google.com/drive/folders/13aKQvYEB-77u9Zr4smSNd4M8LzSQ5k8D?usp=sharing>

Anexo IV. Resumen del cuestionario realizado a Funcionario Público del OECE¹.

N°	Pregunta	Respuesta del Subdirector de Atención de Elevación de Cuestionamientos – Dr. Anthony David Laura Silva
1	Desde su experiencia en la Subdirección de Atención de Elevación de Cuestionamientos ¿cuáles son los errores o deficiencias más recurrentes en las Bases Administrativas?	<p>En obras:</p> <ul style="list-style-type: none"> - Publicación incompleta del expediente técnico en SEACE. - Requerimiento incompleto o distinto al usado en la indagación de mercado. - Factores de evaluación que no cumplen parámetros de las Bases Estándar. - Exceso de documentos exigidos en la presentación de ofertas. - Exigencias restrictivas que limitan concurrencia y competencia sin sustento técnico razonable. - Falta de integración de lo dispuesto en el Pliego de Absolución de Consultas y Observaciones.
2	¿Qué criterios o elementos deberían priorizarse en un sistema automatizado como REVICOP para alertas tempranas?	Relación de documentos a presentar, el requerimiento y los factores; verificar concordancia con la normativa y Bases Estándar. Comprobar si se implementaron todas las disposiciones del Pliego Absolutorio y/o de Acciones de Supervisión, de ser el caso.
3	¿Cómo puede contribuir un modelo predictivo de IA al trabajo del equipo que atiende cuestionamientos?	“Contribuiría muchísimo”: Hoy la revisión es manual y algunos aspectos contrarios a norma pueden no ser advertidos. Un modelo predictivo reduce márgenes de error y, según la oportunidad de uso, permite corregir en la integración de Bases sin declarar nulidad.
4	¿Qué limitaciones o precauciones deben considerarse antes de integrar REVICOP a PLADICOP o al flujo de revisión?	Realizar un periodo de prueba en un grupo reducido de Entidades para evaluar resultados antes de su despliegue amplio.

¹ Se solicitaron entrevistas y se alcanzaron cuestionarios a la Presidencia del OECE, así como a la Dirección del Sistema Electrónico de Contrataciones del Estado - SEACE; sin embargo, no se obtuvo respuesta de los funcionarios a cargo de dichas dependencias.

Las respuestas del Subdirector de Atención de Elevación de Cuestionamientos confirman, desde la operación diaria, que las fallas más recurrentes se concentran en la calidad de las Bases Administrativas: publicación incompleta del expediente técnico en SEACE (obras), incongruencias entre requerimiento e indagación de mercado, factores de evaluación que no siguen las Bases Estándar, exceso de documentos exigidos, exigencias restrictivas sin sustento y omisión de integrar lo dispuesto en el pliego de consultas y observaciones. Este patrón valida el problema estructural que aborda la presente investigación (revisión manual limitada frente a alto volumen) y, a la vez, ofrece reglas precisas para entrenar REVICOP.

Además, el Dr. Laura Silva anticipa la utilidad directa de REVICOP, calificándolo como un modelo predictivo que “contribuiría muchísimo” al reducir errores de omisión propios de la revisión manual y permitir correcciones antes de integrar bases, evitando nulidades. También recomienda un piloto controlado en un grupo reducido de entidades, lo que encaja con una estrategia de despliegue gradual y con la medición del indicador de efectividad de alertas (PPV). En síntesis, la evidencia recogida respalda la viabilidad técnica y la pertinencia institucional de REVICOP.

Anexo V. Interfaz del Revisor Inteligente de las Contrataciones Públicas.



Nota. Elaboración Propia, y ejecutada en Python.

(Supresión del código fuente por reserva de autoría).

Anexo VI. Matriz de Entrenamiento y Diccionario de Variables de REVICOP

La presente investigación sustenta sus resultados en una matriz de datos compuesta por 20,000 registros simulados que replican escenarios técnicos de supervisión, Debido a la extensión de la matriz (20,000 registros), el dataset completo en formato .xlsx se encuentra disponible para revisión y/o consulta en el siguiente enlace de repositorio digital:

<https://drive.google.com/drive/folders/1ZeZKYIVpe54o1nO4Kqbmp5NC37xqnM4J?usp=sharing>

Lógica de Calificación del Resultado:

Los valores de la columna RESULTADO en la matriz de datos se asignaron atendiendo las disposiciones de la normativa de contrataciones vigente:

- * Valor 1 (Conforme): Asignado cuando las 23 variables anteriores tienen valor "1" (Cumple).
- * Valor 0.5 (Observado): Asignado si el objeto (O1) es correcto, pero existe al menos un "0" en las otras 22 variables de control o requerimiento.
- * Valor 0 (Rechazado): Asignado si existe una falla crítica en la variable O1.

Por su parte, a continuación, se detalla el significado de cada columna (variable) y los criterios utilizados para determinar el valor de la columna RESULTADO que se encuentra en el archivo contenido en el enlace *supra*, la cual funcionó como el parámetro de comparación para el entrenamiento del Modelo.

Resumen del Dataset:

Dimensión	Variable	Descripción Técnica (Criterio de Evaluación)
Objeto	O1	El objeto de la contratación no corresponde con el tipo de bases estándar.
Cuantía	CC1 - CC3	Incongruencias en valores, límites y falta de fuente de financiamiento.
Admisión	CO1 - CO3	Exceso o falta de documentos para la admisión y requisitos de calificación.

Contrato	RPPC1-2	Documentación mínima o excesiva para perfeccionar el contrato.
Requerimiento	R1 - R14	Finalidad pública, disponibilidad física, adelantos, penalidades, pagos y factores de evaluación.
RESULTADO		Valor asignado según la gravedad de las omisiones detectadas.

Nota biográfica

Francisco Roberto Bonnett Escobar

Nació el 09 de febrero de 1989 en el distrito de Jesús María, Lima Perú. Es abogado egresado y titulado de la Pontificia Universidad Católica del Perú. Es egresado de la Maestría en Contrataciones del Estado y candidato al grado de Magíster en Gestión Pública, tiene especializaciones en Arbitraje de Inversiones, Derecho Administrativo y Gestión Pública. Cuenta con más de doce años de carrera profesional en el ámbito de las contrataciones con el Estado y Arbitraje, asesorando a distintas empresas privadas y entidades públicas como el Ministerio de Vivienda, Construcción y Saneamiento, Ministerio de la Producción, Ministerio de Cultura, entre otros, y ha trabajado seis años como especialista de la Subdirección de Identificación de Riesgos que afectan la Competencia de la Dirección de Riesgos del OSCE (hoy Subdirección de Atención de Elevación de Cuestionamientos del OECE); actualmente es consultor de proyectos financiados por el Banco Mundial. Se ha desempeñado como ponente en diferentes eventos académicos en materia de Contratación Pública y Arbitraje. Es Fedatario Público Juramentado con Especialización en Informática; es socio fundador de Bonnett & Asociados Consultores, y de la Sociedad de Derecho Digital e Inteligencia Artificial en el Perú.