

+INGENIO

Revista de Ciencia Tecnología e Innovación

Edición julio-diciembre 2025 Vol. 6 N° 2

ISSN 2618-5520 on line

FACULTAD DE INGENIERÍA UNaM

AUTORIDADES

Decana: Mtr. Ing. María Claudia Dekun
Vicedecano: Mgter. Ing. Hugo Orlando Reinert
Secretaria Académica: Arq. Hilda Marta Adelina Cámpora
Secretario de Ciencia y Técnica: Mgter. Ing. Alejandro J. Kerkhoff
Secretario de Posgrado: Mgter. Ing. Carlos Rubén Brázzola
Secretario de Extensión: Mgter. Ing. Marco Paolo Bárbaro
Secretaria de Asuntos Estudiantiles: Ing. Florencia Rocío E. Lima
Secretaria Administrativa: L.G.U. Silvina Luciana Barrios

EQUIPO EDITORIAL

DIRECCIÓN EDITORIAL

Editor en Jefe

Dr. Ing. Rubén Orlando Núñez

Co-Editores

PostDr. Ing. Mario Orlando Oliveira
PostDr. Ing. Mario José Mantulak
PostDr. Ing. Gustavo O. Bogado
PostDr. Ing. Juan Esteban Miño Valdés

DIRECCIÓN EDITORIAL

Dr. Ing. Arturo Suman Bretas. Universidad de Florida. Estados Unidos
Dr. Ing. José Renes Pinheiro. Universidad Federal de Santa María. Brasil
Dr. Ing. Daniel Gustavo Allasia Piccilli. Universidad Federal de Santa María. Brasil
Dr. Ing. Alejandro Germán Frank. Universidad Federal de Río Grande del Sur. Brasil
Dr. Ing. Gilberto Dionisio Hernández Pérez. Universidad Central de Las Villas. Cuba
Dr. Ing. Erenio Gonzalez Suarez. Universidad Central de las Villas. Cuba
Dr. Ing. Amaury Pérez Martínez. Universidad Estatal Amazónica. Ecuador.
Dr. Ing. Juan Carlos Michalus. Universidad Nacional de Misiones. Argentina
Mgter. Ing. Victor Andrés Kowalski. Universidad Nacional de Misiones. Argentina
Mgter. Arq. Delia Klees. Universidad Nacional del Nordeste. Argentina
Dr. Ing. Gustavo Aucar. Universidad Nacional del Nordeste. Argentina
Dr. Ing. Jorge Víctor Pilar. Universidad Nacional del Nordeste. Argentina
Dr. Ing. Mario De Bórtoli. Universidad Nacional del Nordeste. Argentina
Dra. Ing. Gabriela Corsano. CONICET-UTN, Universidad Nacional del Litoral. Argentina
Dra. Ing. Ada Judith Franco. Universidad Nacional de Salta. Argentina
Dra. Ing. Nora Okulik. Universidad Nacional del Chaco Austral. Argentina
Dr. Ing. Raymundo Quilez Forradellas Martínez. Universidad Nacional de Cuyo. Argentina
Mgter. Ing. Liliana Raquel Cuenca Pletsch. Universidad Tecnológica Nacional. Argentina
Dr. Ing. Oscar Möller. Universidad Nacional de Rosario. Argentina
Dr. Ing. Guillermo Rubén Bossio. Universidad Nacional de Río Cuarto. Argentina
Mgter. Ing. Raúl Barral. Universidad Nacional de Río Cuarto. Argentina
Dr. Ing. Gustavo Ernesto Maffia. Universidad Nacional de la Plata. Argentina
Dr. Alejandro Yawny. Instituto Balseiro (CAB). Argentina

Revisor de estilo para el idioma inglés

Dra. Lic. en Lengua Inglesa Gladys González Carreras. Universidad Nacional de Misiones. Facultad de Ingeniería. Misiones. Argentina.
Mgter. Lic. en Inglés Graciela Noemi Fritz. Universidad Nacional de Misiones. Facultad de Ingeniería. Misiones. Argentina.

Índice

05

Nota editorial

Mgter. Ing. Kerkhoff Alejandro Javier

07

Prólogo

Dr. Ing. Mario Orlando Oliveira .

09

Diseño Hidráulico y Verificación Estructural del Álabes de Microturbina Tipo Pelton.

Ariel Ricardo Marchegiani, Lautaro Cepeda.

18

Mitigación de inundaciones urbanas: Diseño de la Estación de Bombeo del Sistema Lagunar Rissione.

Carlos Alberto Depettris, Jorge Victor Pilar, Guillermo José Mendez, Marcelo Justo Manuel Gómez, Alejandro Ricardo Ruberto.

32

Predicción de Costos y Plazos en Proyectos de Construcción: Un enfoque Basado en Inteligencia Artificial.

Miryan R. Puchini, Nancy B. Ganz, Yolanda E. Zado.

61

Impacto Hidrológico de la Infraestructura Vial Rural Sobre la Dinámica de la Cuenca Polvorín Palometa.

Lucas E. Álvarez, Guillermo J. Mendez I, Alejandro R. Ruberto, Jorge V. Pilar, Marcelo J. M. Gómez, Carlos A. Depettris.

74

Desafíos y Oportunidades de Ingeniería de Requerimientos asistida por LLM y Prompt Engineering.

Fernando Corinaldesi, Hernán Ariel Domínguez, Briant Alcides Gauna.

90

Caracterización de Muros EPS – MC y Comparativas con Casos Convencionales.

Javier A. Duarte, Alicia E. Ares, Oscar Möller, Néstor H. Neudeck, María B. Statkiewicz.

COMITE DE REVISIÓN

Dr. Ing. Aldo Luis Caballero
Mgtr. Ing. Gabriel Alejandro Tarnowski
Dr. Lic. Eduardo Zamudio
Ing. Jose Luis Golemba
Dr. Ing. Jonathan Emmanuel Ochoa Sosa
Dr. Ing. Miguel Aguirre
Dr. Ing. Roberto Estaban Carballo

EQUIPO TÉCNICO

Soporte Técnico:

Lic. Miryan Rosana Puchini. Universidad Nacional de Misiones. Facultad de Ingeniería. Misiones. Argentina.
Ing. Yolanda Stefani Zado. Universidad Nacional de Misiones. Facultad de Ingeniería. Misiones. Argentina.

COLABORADORES

Diseño de Tapa y Formato de Publicación:

D.G. Damián Leandro Kallus. Universidad Nacional de Misiones. Facultad de Arte y Diseño. Misiones. Argentina.

Dirección de Tecnologías de la Información y Comunicaciones

A.S.C. Evaldo Meinl. Universidad Nacional de Misiones. Facultad de Ingeniería. Misiones. Argentina.
Lic. Lucas Podkowa. Universidad Nacional de Misiones. Facultad de Ingeniería. Misiones. Argentina.

EDITORIAL RESPONSABLE

Universidad Nacional de Misiones (UNaM). Facultad de Ingeniería (FI). C.P.: 3360 Juan Manuel de Rosas 325, Oberá, Misiones, Argentina. Es una publicación de la Secretaría de Ciencia y Técnica y la Secretaría de Posgrado de la Facultad de Ingeniería de la UNaM.



UNIVERSIDAD
NACIONAL
DE MISIONES



FACULTAD
DE INGENIERÍA
UNaM

Nota Editorial

Es un motivo de profunda satisfacción presentar este nuevo número de la revista +INGENIO, publicación científica de la Facultad de Ingeniería de la Universidad Nacional de Misiones (UNaM). Como espacio consolidado para la difusión de la ciencia, la tecnología y la innovación, este volumen reafirma nuestro compromiso con la generación de conocimiento original que no solo atienda a los estándares internacionales de excelencia, sino que también brinde soluciones tangibles a las problemáticas de nuestra región.

En un contexto global marcado por la transformación digital, la sostenibilidad energética y la optimización de procesos, la ingeniería se posiciona como el puente indispensable entre la teoría científica y el desarrollo social. Los artículos de este número reflejan esa diversidad temática, abordando los desafíos de un ecosistema educativo que ha dejado de ser lineal.

La irrupción de la Inteligencia Artificial (IA) y la automatización define el rol del ingeniero. Esto nos obliga a repensar nuestras prácticas docentes y líneas de investigación. En este escenario, el trabajo de nuestros docentes es vital: son estos investigadores quienes, con rigor y ética, deben liderar la adopción de estas herramientas para potenciar la creatividad humana, nunca para reemplazarla.

Sin embargo, el progreso tecnológico carece de sentido si no se enmarca en el compromiso ambiental. La crisis climática global nos exige soluciones urgentes perdurables en el largo plazo. Desde la FI-UNaM, asumimos como prioridad el uso racional de la energía y el desarrollo de tecnologías sostenibles. En nuestros laboratorios y aulas se trabaja incansablemente para que la eficiencia energética y la preservación de nuestra biodiversidad sean ejes transversales en todas las carreras, cumpliendo así con el mandato social que nuestro Estatuto nos confiere como Universidad.

La revista +INGENIO se consolida como el espacio de convergencia de esta diversidad disciplinar. Su potencial radica en su capacidad de integrar el conocimiento local con una visión internacional. Nuestra ubicación estratégica en la zona de la Triple Frontera es geográfica, geopolítica y académica, posición que nos impulsa a una integración regional profunda y al fortalecimiento de redes de cooperación con universidades extranjeras, permitiendo un flujo constante de ideas que trascienden las fronteras nacionales.

Sin embargo, necesitamos entender y hacernos eco de la realidad que nos rodea, no podemos ignorar la realidad que nos circunda. Hemos pasado de proyectar crecimiento a enfrentar el desafío de la supervivencia básica del sistema científico. La inversión en Ciencia y Tecnología ha caído a niveles críticos, se han dado de baja programas históricos y nuestros investigadores se encuentran ante una encrucijada que alimenta la fuga de cerebros y la pérdida de soberanía tecnológica.

Este número es testimonio de ese esfuerzo colectivo. En sus páginas encontrarán investigaciones que dialogan con el mundo, pero que mantienen los pies firmes en la tierra colorada, desarrollo tecnológico situado, acciones orientadas al bienestar comunitario, promoviendo y aportando al desarrollo soberano de nuestra nación, a pesar de las decisiones inciertas y cuestionables de la gestión nacional en turno, buscando el bienestar de nuestra comunidad y el desarrollo soberano de la nación.

Invitamos a la comunidad científica y profesional a sumergirse en estos artículos, con la certeza de que la ingeniería, impulsada por la inteligencia y la ética, es la herramienta más poderosa para construir un futuro más justo, eficiente y sostenible.

Mgter. Ing. Kerkhoff Alejandro Javier
Secretario de Ciencia y Técnica. Facultad de Ingeniería-UNaM

Prólogo

La ingeniería contemporánea enfrenta desafíos crecientes asociados a la sostenibilidad energética, la gestión de los recursos naturales, la resiliencia de las infraestructuras y la digitalización de los procesos productivos. En este contexto, la generación y difusión de conocimiento científico resulta fundamental para promover soluciones tecnológicas innovadoras que contribuyan al desarrollo económico y social.

En esta línea, +INGENIO, revista científica de la Facultad de Ingeniería de la Universidad Nacional de Misiones orientada a la difusión de investigaciones en ingeniería y tecnología, presenta un nuevo número que reúne investigaciones en áreas estratégicas como la ingeniería energética, la ingeniería hidráulica, la ingeniería civil y las tecnologías digitales emergentes. Los trabajos incluidos abordan temas vinculados con el diseño hidráulico y estructural de microturbinas hidroeléctricas, la planificación de infraestructuras hidráulicas para la mitigación de inundaciones y el análisis de la interacción entre infraestructura vial y dinámica hidrológica en cuencas de llanura. Asimismo, se presentan investigaciones relacionadas con la aplicación de herramientas de inteligencia artificial en la gestión de proyectos de construcción y en la ingeniería de requerimientos de software. La edición se completa con estudios experimentales orientados al análisis de materiales y sistemas constructivos alternativos, aportando evidencia para el desarrollo de soluciones constructivas más eficientes y sostenibles.

En conjunto, las contribuciones de este número reflejan el valor de la investigación aplicada y del intercambio académico como motores de innovación tecnológica para enfrentar los desafíos tecnológicos actuales. Desde su creación, +INGENIO busca consolidarse como un espacio de difusión científica que promueve el diálogo entre investigadores, profesionales y estudiantes de ingeniería.

El Equipo Editorial agradece especialmente a los autores por confiar sus investigaciones a la revista, a los revisores por su rigurosa labor en el proceso de evaluación y a todos los colaboradores que contribuyen al crecimiento sostenido de la revista y al fortalecimiento de la difusión del conocimiento científico en ingeniería.

Dr. Ing. Mario Orlando Oliveira
Co-Editor +INGENIO. Facultad de Ingeniería-UNaM

Diseño Hidráulico y Verificación Estructural del Álabo de Microturbina Tipo Pelton

Ariel Ricardo Marchegiani^{1,*} , Lautaro Cepeda¹ 

¹ Universidad Nacional del Comahue, Facultad de Ingeniería. Neuquén, Argentina.

e-mails: ariel.marchegiani@fain.uncoma.edu.ar

Resumen

El diseño de las pequeñas turbinas hidráulicas como las turbinas Pelton y otras turbinas de impulso se ha basado en los conocimientos técnicos existentes, en general de grandes máquinas, y las mejoras de diseño se realizaban principalmente tras extensas pruebas experimentales mediante el método de ensayo y error. En los últimos tiempos se ha realizado un gran esfuerzo para comprender mejor los detalles del complejo flujo en este tipo de máquinas, con la ayuda de la dinámica de fluidos computacional (CFD) y la modelización numérica moderna.

En el presente trabajo se realizó el diseño de un álabo de microturbina Pelton. Se diseñaron dos modelos tentativos del álabo y se seleccionó el de mejor rendimiento en base simulaciones CFD realizadas sobre dichos modelos. Estas simulaciones se contrastaron con lo que predice la teoría unidimensional de las máquinas hidráulicas.

Además, se realizó la selección del material más adecuado para este tipo de turbinas, poniendo foco en materiales que presenten altos valores de dureza y buena resistencia a la oxidación.

Se realizó la verificación estructural del modelo, incluyendo resistencia del álabo a la fatiga, llevando a cabo simulaciones fluido dinámicas donde se estudió el impacto del jet de agua contra el álabo y estos resultados se utilizaron para verificar estructuralmente el álabo en distintas condiciones de uso de la turbina, como por ejemplo, turbina detenida y en movimiento, con los tornillos de sujeción con precarga y sin ella. Todas estas condiciones fueron contrastadas con lo que se predijo en forma teórica.

El uso de estas técnicas puede reducir considerablemente las costosas pruebas experimentales que se realizan mediante el método de prueba y error en el campo de las pequeñas turbinas hidráulicas.

Palabras Clave – Microturbina Pelton, Alabe, CFD, Propiedades Mecánicas.

Abstract

The design of small hydraulic turbines such as Pelton turbines and other impulse turbines has been based on existing technical knowledge, generally from large machines, and design improvements were mainly made after extensive experimental testing using trial and error. In recent times, a great effort has been made to better understand the details of the complex flow in this type of machine, with the help of computational fluid dynamics (CFD) and modern numerical modeling.

In this work, the design of a Pelton microturbine blade was carried out. Two tentative models of the blade were designed, and the one with the best performance was selected based on CFD simulations performed on these models. These simulations were compared with the predictions of the one-dimensional theory of hydraulic machines.

In addition, the most suitable material for this type of turbine was selected, focusing on materials with high hardness values and good resistance to oxidation.

The structural verification of the model was carried out, including blade fatigue resistance, by performing fluid dynamics simulations where the impact of the water jet against the blade was studied. These results were used to structurally verify the blade under different conditions of turbine use, such as when the turbine is stopped and in motion, with and without preloaded fastening screws. All of these conditions were compared with what was predicted theoretically.

The use of these techniques can significantly reduce the costly experimental testing carried out using the trial and error method in the field of small hydraulic turbines.

Keywords – Pelton Microturbine, Blade, CFD, Mechanical Properties.

1. Introducción

La creciente demanda de energía eléctrica en las últimas décadas y la necesidad de incrementar el uso de energías limpias ha impulsado el desarrollo de nuevas tecnologías como la energía solar y la energía eólica. Sin embargo, las viejas tecnologías como las turbinas hidráulicas continúan teniendo protagonismo en el mundo de las energías renovables, sobre todo en zonas cordilleranas donde los grandes saltos de agua disponibles resultan ser muy interesantes para su explotación y donde la implementación de las restantes energías renovables es más dificultosa o menos eficiente.

En este contexto es que las microturbinas Pelton (Fig. 1) encuentran aplicación en aquellos lugares aislados de la red eléctrica, donde no se requieren grandes cantidades de energía y existen pequeños cursos de agua con grandes saltos aprovechables.




Fig. 1. Microturbina Pelton.

Uno de los componentes principales de las turbinas Pelton es el álabe o cuchara. A lo largo de la historia de las turbinas Pelton los álabes han ido mejorando su rendimiento, pero en esencia no han cambiado en su forma básica. Las cucharas están formadas por dos semi elipsoides que comparten un borde o filo en común. Las cucharas se ubican en la periferia de un rodete macizo (disco) y el jet de agua impacta tangencialmente al mismo. El agua se divide exactamente en dos partes iguales por el filo de la cuchara y es desviada casi 180° entregando la mayor cantidad posible de energía al rodete. El jet de agua se divide en dos partes iguales para cancelar las fuerzas axiales sobre el eje del rodete.

1.1. Diseño Hidráulico

Lo primero que se debe definir es la altura neta de la turbina H_N . Esta altura se define como la altura que es puesta a disposición de la turbina y es igual a la diferencia de alturas totales entre la entrada (E) y la salida de la turbina (S), $H_N = H_E - H_S$. En el caso de las turbinas Pelton la entrada se considera que es el inyector y la salida es la cuchara. Pero como en estas turbinas el intercambio de energía se realiza a presión atmosférica se puede decir que $H_S = 0 \text{ m}$. Con lo cual, $H_N = H_E$ y la altura neta es igual a la altura a la entrada en el inyector.

Una vez que el agua sale a la atmósfera se convierte toda la energía de presión disponible a la entrada en energía cinética menos las pérdidas en el inyector. La velocidad del chorro de agua está dada por la ecuación de Torricelli,

$$c_1 = k_c \sqrt{2 \cdot g \cdot H_N} \quad (1)$$

Donde k_c es el rendimiento del inyector igual a 0,98 como valor habitual [1].

De consultas realizadas con fabricantes regionales y nacionales, y por propia experiencia, las alturas aprovechables en nuestro país para este tipo de máquinas están entre 40 y 100 m. Se define

entonces la altura de diseño en un valor de 70 metros. Cabe aclarar que el diseño propuesto podrá ser usado con otras alturas.

Las turbinas Pelton son turbinas tangenciales, y, por lo tanto, la velocidad periférica a la entrada y a la salida de la cuchara es la misma para radios homónimos. Si la turbina gira a una velocidad n (rpm), la velocidad tangencial es igual a

$$u = u_1 = u_2 = n \cdot \frac{2\pi}{60} \cdot \frac{D}{2} \quad (2)$$

Dónde $D=2.R$ es el diámetro primitivo del rodete. Este diámetro es particularmente importante porque el centro del chorro de agua debe ser tangente al mismo (ver Fig. 2).

Otros diámetros característicos son: Diámetro del rodete $D_a=2.R_a$, Diámetro de la punta del splitter o filo, $D_s=2.R_s$ y Diámetro del inyector, d_0 .




Fig. 2. Definiciones de diámetros en turbinas Pelton [2].

La determinación del diámetro primitivo del rodete está influenciada por la velocidad de rotación del generador (debido a su número de polos) y por la velocidad del chorro de agua. Es sabido que, si la energía eléctrica generada por la turbina es vertida directamente a la red eléctrica, la frecuencia de la electricidad debe ser constante e igual a 50 Hz. En nuestro caso, se decidió dejar sujeta la selección del generador a la disponibilidad del mercado; y se decidió fijar el diámetro primitivo en $D = 300$ mm. Otro parámetro adoptado en función de la experiencia adquirida a través del tiempo en el Laboratorio de Máquinas Hidráulicas, es el diámetro del chorro d_0 el cual se fijó, para las condiciones planteadas, en un valor de 30 mm.

La velocidad absoluta del agua (c_1) y la velocidad periférica del rodete (u_1) ya son conocidas para todos los filamentos que coinciden con el diámetro primitivo D , entonces es posible calcular la velocidad relativa del agua (w_1) respecto de la cuchara a partir de $\vec{w}_1 = \vec{c}_1 - \vec{u}_1$. De esta manera, el triángulo de velocidad al ingreso de la cuchara es el mostrado en la Fig. 3.




Fig.3. Triángulos de velocidades de una turbina Pelton.

Se observa en dicha figura, que el chorro de agua se divide en dos partes iguales a partir del filo de la cuchara y se produce un desvío que idealmente es de 180° para que se produzca la máxima fuerza sobre la cuchara. Si se supone que no existe fricción en la cuchara entonces la velocidad relativa al ingreso es la misma que a la salida, $w_1 = w_2$, con lo cual la velocidad absoluta a la salida de la cuchara sería igual a cero. Este sería el caso ideal. En realidad, no es posible que el agua se desvíe 180° porque el agua que sale de una cuchara impactaría en el dorso de la siguiente cuchara, generando un momento contrario al sentido de giro frenando el rodete. Además, existe fricción en la cuchara y la velocidad relativa a la salida no es igual a la velocidad relativa a la entrada. Teóricamente, la velocidad periférica u debería ser igual a la mitad de la velocidad del chorro c , como se observa en la Fig. 3. En la realidad, la velocidad periférica, y su coeficiente de velocidad periférica $k_u = \frac{u}{\sqrt{2gH}}$, se debe obtener en un banco de pruebas y se ha encontrado que su valor óptimo ronda entre 0,44-0,46 con un valor medio habitual de 0,45 [2].

1.2. Fuerza y potencia en turbinas Pelton

Según la teoría unidimensional es posible tomar una línea de corriente en representación de todo el flujo para poder calcular la fuerza que ejerce el chorro sobre la cuchara a partir del Teorema de Transporte de Reynolds aplicado a la cantidad de movimiento lineal, en un volumen de control como el de la Fig. 4.




Fig. 4. Volumen de control en movimiento de traslación y fuerza externa [2].

El teorema se escribe como sigue,

$$\frac{d}{dt} \cdot (B_{sist}) = \frac{d}{dt} \left(\int_{cv} \beta \cdot \rho \cdot dVol \right) + \int_{cs} \beta \cdot \rho \cdot \left(\vec{v} \cdot \vec{n} \right) dA \quad (3)$$

Donde:

- B es una propiedad que puede ser masa, cantidad de movimiento, cantidad de movimiento angular o energía.
- β es la propiedad intensiva de B.
- cv , es el volumen de control.
- cs , es la superficie de control.
- $\vec{v}$, es la velocidad a la que ingresa o egresa la propiedad B.
- $\vec{n}$, vector normal a la superficie de control.

Aplicando el Teorema de Transporte de Reynolds se obtiene la fuerza que ejerce el chorro de agua sobre el volumen de control, o sea, la cuchara, teniendo en cuenta las siguientes hipótesis: El eje z está alineado con el centro del jet de agua, No existen variaciones de densidad en el sistema, $\rho = \rho_1 =$

ρ_2 , el sistema es estacionario. Luego, el término de la variación en el tiempo es nulo, y No existe fricción en el álabe, con lo cual, $w_1 = w_2 = w$.

Con estas hipótesis se obtiene lo siguiente,

$$F_z = \dot{m}w(1 + \cos(\beta_2)) \quad (4)$$

Y la potencia es igual a la fuerza multiplicada por la velocidad de traslación de la cuchara o del volumen de control,

$$P = F_z u = \dot{m}w(1 + \cos(\beta_2))u \quad (5)$$

Observar que si $\beta_2 = 0^\circ$, es decir, que el flujo de agua da un giro de 180° , la potencia y la fuerza es máxima.

De acuerdo a esto, y para los parámetros adoptados, mencionados anteriormente se obtuvieron los parámetros de operación que se muestran en la tabla 1. Los mismos son usados en las simulaciones realizadas.

Tabla 1. Parámetros de funcionamiento obtenidos

c_1 [m/s]	u_1 [m/s]	Q [m ³ /s]	n [r.p.m]	F_z [N]*[a]	F_z [N]**[b]	P [kW]
36,32	16,34	0.256	1601,7	1832,9	824.8	13.48

1.3. Geometría de la cuchara y número de cucharas

La bibliografía disponible [1] [3] define las principales dimensiones de las cucharas en función del parámetro conocido como relación de diámetros. Existen límites máximos y mínimos para esta relación de diámetros donde el rendimiento se mantiene en niveles aceptables. La bibliografía recomienda que la relación de diámetro se encuentre entre 1/30 y 1/9.

Si la relación es excesivamente pequeña el chorro de agua pierde calidad al tener que recorrer un largo camino desde el inyector hasta el rodete. Además, al incrementarse el diámetro del rodete, aumenta el número de cucharas dificultando la evacuación del agua. Por el contrario, si la relación es muy grande, el número de cucharas disminuye y aumentan su tamaño, dificultándose el alojamiento de las mismas en el rodete. Esto produce también que el rendimiento disminuya al no poder aprovechar la totalidad del agua.

De acuerdo a esto se diseñaron dos modelos de cuchara para los extremos de los rangos recomendados, los que se observan en la Fig. 5.

Para determinar el número de cucharas de cada modelo se aplicaron los métodos de los diferentes autores [1] [2]. Los resultados se muestran en la tabla 2.

Tabla 2. Determinación del Número de Cucharas

Referencia	Rango Inferior	Rango superior
[1]	17	14
[2]	22	19

Finalmente, analizando los diseños planteados, se adoptaron 22 cucharas para el rango Inferior y 19 cucharas para el rango superior.




Fig. 5. Modelos de cuchara diseñados.

2. Simulación numérica del flujo

El dominio computacional a analizar es un prisma que cubre la cuchara y el inyector. Las celdas del dominio son cúbicas y tienen un tamaño de 15mm, como se muestra en la Fig. 6. La cuchara se ubicó en una posición tal que una de las cucharas se encuentra a punto de interceptar su filo con el chorro de agua. Con el fin de reducir tiempo de cálculo se definieron dos subdominios adicionales. Cada uno de ellos recibió refinamientos independientes de las celdas del dominio global. De esta manera, se definió un primer subdominio cilíndrico concéntrico al chorro de agua y un segundo subdominio sobre las caras internas de la cuchara y la cara del inyector.




Fig. 6. Dominio computacional.

Se realizó un estudio de convergencia de mallas (Fig. 7) y finalmente se adoptó una malla de aproximadamente 203.000 celdas (DP4 en la Fig. 7).




Fig. 7. Análisis de convergencia.

2.1. Comparación de los resultados con la teoría unidimensional

Como se mostró en el anteriormente, se calculó la fuerza que ejerce el agua sobre la cuchara a partir de la teoría unidimensional. Dicha teoría se basa en ciertas hipótesis que permiten simplificar el problema, pero esta teoría solo es capaz de predecir el valor de la fuerza en el sentido del eje z , mientras que las simulaciones nos brindan la fuerza del jet de agua en todos los ejes coordenados. En este punto es posible comparar los resultados obtenidos a partir de la teoría con los resultados de la simulación.

La simulación arrojó un valor de la fuerza en z de $|F_z| = 1580,6$ N, lo que representa una diferencia porcentual del 13,76%. Como ya se mencionó, esta diferencia se debe a que la simulación es capaz de representar el flujo del agua sobre la cuchara, mientras que la teoría unidimensional solo tiene en cuenta una línea de corriente y se asume que todo el flujo sigue dicha trayectoria. En la Fig. 8 se muestran imágenes de la simulación donde se graficaron 200 líneas de corriente que permiten visualizar la diferencia entre la teoría unidimensional y la simulación. Las distintas tonalidades de las líneas de corriente representan el módulo de la velocidad, donde el color rojo son las mayores velocidades y el color azul las menores velocidades.




Fig. 8. Resultados de la simulación mediante CFD.

3. Análisis Tensional

Se realizó la verificación de las tensiones para la cuchara en posición estática y en movimiento.

3.1. Cuchara estática

Se realizó el análisis de tensiones para la turbina detenida. En esta posición la cuchara recibe toda la energía del agua, y, por lo tanto, la cuchara se encuentra bajo las máximas solicitaciones posibles

por efecto del agua. Sin embargo, como se verá más adelante, cuando la turbina se pone en movimiento, el efecto del agua disminuye y el módulo de la fuerza centrífuga se incrementa, tornándose comparable con la fuerza ejercida por el agua.

En la Fig. 9 se puede observar como el filo de la primera cuchara de la izquierda está a punto de entrar en contacto con el chorro de agua. Con esta posición de la cuchara se realizaron las simulaciones fluidodinámicas y los resultados se utilizaron para dimensionar los pernos y para realizar las simulaciones de tensiones sobre la cuchara.

3.2. Dimensionamiento de los Pernos

Para dimensionar los pernos se deben analizar dos situaciones. Una donde a los pernos se les aplica la precarga necesaria para sujetar las partes con firmeza, y otra, donde por cuestiones operativas de la turbina (vibraciones y sucesivos impactos del agua, la precarga se pierde y los pernos pasan a trabajar a corte puro y aplastamiento. En este último caso, también se debe verificar el aplastamiento de los brazos de la cuchara.




Fig. 9. Fuerzas intervinientes en la cuchara.

En toda unión atornillada los pernos se precargan para que la fricción generada entre las partes sea quien toma toda la carga aplicada. El cálculo se llevó a cabo siguiendo la metodología de autores pertinentes [4]. Los resultados se muestran en la tabla 3.

Tabla 3: Fricción generada por el pretensado del perno.

Ø	Área de prueba, A_t [mm ²]	Fuerza de pretensado, F_i [N]	Fuerza de fricción [N]
M8	36,6	10500	1575
M10	58	16639	2496
M12	84,3	24184	3628

Como se puede observar, se debe seleccionar pernos M10 para resistir una fuerza de aproximadamente 1800 N cuando la turbina se encuentra detenida.

Si los tornillos pierden su fuerza de pretensado, se debe verificar los tornillos a corte y aplastamiento, y los brazos de la cuchara solamente a aplastamiento (en nuestro caso no existe la posibilidad de desgarramiento porque las cucharas se apoyarían unas contra otras).

En la Fig. 9 se puede observar que las fuerzas son excéntricas respecto del centro de pivote de los agujeros, con lo cual se debe aplicar un método de cálculo particular para determinar las fuerzas existentes sobre los pernos.

De los cálculos y las simulaciones llevadas adelante se pudo concluir que la cuchara no falla bajo cargas estáticas cuando se pierde la fuerza de pretensado.

En la Fig. 10 pueden observarse algunos resultados de las simulaciones.




Fig. 10. Tensiones en la cuchara a) con la turbina detenida, b) con la turbina en movimiento

4. Conclusiones

Se diseñó el álabe de una microturbina Pelton a partir de los parámetros sugeridos por la bibliografía existente y a partir de consultas realizadas a fabricantes locales de este tipo de turbinas. Se utilizó el software SolidWorks para el modelado 3d y la verificación de su aptitud ante las solicitudes mecánicas del caso. Se realizó una investigación y selección de materiales para determinar cuáles serían los más apropiados para esta aplicación. Como muestran los resultados de las simulaciones, las tensiones obtenidas son bajas en comparación con la tensión de fluencia, y esto es consecuencia de que la decisión de seleccionar este material se basó principalmente en el valor de dureza que se alcanza con el tratamiento térmico y no tanto por su tensión de fluencia. Con este material se espera disminuir la velocidad del desgaste y prolongar la vida útil de la cuchara. El uso de estas técnicas puede reducir considerablemente las costosas pruebas experimentales que se realizan mediante el método de prueba y error en el campo de las pequeñas turbinas hidráulicas.

Agradecimientos

El presente trabajo se encuentra enmarcado en el Proyecto de Investigación 04/I-268, Estudio y Desarrollo de Turbomáquinas y Sistemas Asociados Aplicados a Pequeñas Fuentes de Energía Renovable II, aprobado por la Universidad Nacional del Comahue (2022-2025).

Referencias

- [1] C. Mataix, “Estudio y proyecto de las T H tangenciales: Turbinas Pelton” en *Turbomáquinas Hidráulicas*, Madrid, España, ICAI, 2009, Capítulo 13, pp 891-964. ISBN-978-84-8468-252-3.
- [2] Zh. Zhang, “Working Principle of Pelton Turbines” in *Pelton Turbines*, Zurich, Switzerland: Springer-Verlag, 2016, chapter 2, pp 13-28, ISBN 978-3-319-31908-7.
- [3] V. Schnitzer, (2009). “Micro Hydro Power”, GTZ Ger and Hydro, Bammental, Germany, 2009, Vol 118.
- [4] Richard G. Budynas, J. Keith Nisbett, *Diseño en ingeniería mecánica de Shigley*. México, D.F.: Mc Graw-Hill/Interamericana Editores, 2008, ISBN-10: 970-10-6404-6.
- [5] ROBERT L. Norton, (2011). *Diseño de Máquinas. Un enfoque integrado*, México, Cuarta Edición, Pearson Educación, 2011, ISBN: 978-607-32-0589-4.

Mitigación de Inundaciones Urbanas: Diseño de la Estación de Bombeo del Sistema Lagunar Rissione

Carlos Alberto Depettris¹ , Jorge Víctor Pilar^{1, 2, 3} , Guillermo José Mendez^{1, 3} ,
Marcelo Justo Manuel Gómez^{1, *} , Alejandro Ricardo Ruberto¹ 

¹ Universidad Nacional del Nordeste. Facultad de Ingeniería. Chaco, Argentina.

² Universidad Nacional de Misiones. Facultad de Ingeniería. Misiones, Argentina.

³ Administración Provincial del Agua (APA). Provincia del Chaco, Argentina.

e-mails: carlosdepettris@gmail.com, jvpilar@gmail.com, guillemendez79@gmail.com, mgichaco@yahoo.com.ar,
aleruberto44@yahoo.com.ar

Resumen

El diseño hidráulico de la estación de bombeo correspondiente al sistema lagunar Rissione se desarrolló en el marco de las obras que conforman el sistema de defensas del Área Metropolitana del Gran Resistencia (Chaco, Argentina), con el propósito de dotar a la infraestructura de una capacidad de respuesta adecuada frente a precipitaciones de elevada intensidad. El proceso de diseño consideró la Resolución N.º 303/17 de la Administración Provincial del Agua del Chaco, normativa que establece la cota de línea de ribera y la línea de restricción severa para las lagunas comprendidas en el área metropolitana. La función principal de la estación de bombeo es transferir los caudales excedentes generados en una cuenca de aporte de 517 hectáreas, los cuales se almacenan de manera transitoria en el sector interno o área defendida cuando el río Negro registra niveles superiores a los de las lagunas. En tales condiciones, la evacuación se efectúa hacia el cauce principal a través de su planicie de inundación mediante el sistema de bombeo proyectado. Las líneas de riesgo hídrico, junto con las características hidrológicas y morfológicas del cuerpo lagunar y su articulación con la trama urbana, constituyen los condicionantes fundamentales que delimitan el diseño integral del sistema.

Palabras Clave – Sistema lagunar, Línea de ribera, Llanura, Control de inundaciones, Modelación hidrológica.

Abstract

The hydraulic design of the pumping station associated with the Rissione lagoon system was developed within the framework of the works that constitute the flood defense system of the Greater Resistencia Metropolitan Area (Chaco, Argentina), with the purpose of providing the infrastructure with an adequate response capacity to high-intensity rainfall events. The design process took into account Resolution No. 303/17 of the Provincial Water Authority of Chaco, a regulation that establishes the elevation of the riverbank line and the severe restriction line for the lagoons included in the metropolitan area. The main function of the pumping station is to transfer the excess flows generated in a 517-hectare catchment, which are temporarily stored in the inner sector or protected area when the Negro River reaches levels higher than those of the lagoons. Under such conditions, evacuation is carried out towards the main river channel and its floodplain through the projected pumping system. The flood risk lines, together with the hydrological and morphological characteristics of the lagoon body and its interaction with the urban fabric, constitute the fundamental boundary conditions that determine the integral design of the system.

Keywords – Lagoon system, Shoreline, Plain, Flood control, Hydrological modeling.

1. Introducción

El objetivo de este trabajo ha sido analizar, a partir de un diseño avanzado de los componentes de la Estación de Bombeo del sistema lagunar Rissione (ver Fig. 1), la capacidad de respuesta del conjunto frente a las demandas de la red interna de desagües pluviales, en el marco del esquema definido para las obras de defensa del Área Metropolitana del Gran Resistencia (Chaco, Argentina) [1]-[2].

El funcionamiento del recinto del río Negro, ante excedentes hídricos de distinta magnitud y períodos de recurrencia, se encuentra regulado mediante pautas de operación específicas para los diferentes escenarios posibles. Dichas pautas han sido establecidas por la autoridad de aplicación del Código de Aguas de la Provincia del Chaco, la Administración Provincial del Agua (APA), constituyendo un factor determinante en el dimensionamiento hidráulico de la estación de bombeo de la laguna Rissione.

En este contexto, la Resolución N.º 303/17 de la APA [3] fija la cota de línea de ribera de la Laguna Rissione en 46,76 m MOP y la cota de restricción severa en 47,29 m MOP, del mismo modo que lo hace para las demás lagunas comprendidas dentro del recinto urbano defendido en el Área Metropolitana. Estos instrumentos normativos, legalmente vigentes, resultan esenciales para la delimitación del dominio del estado público provincial al cual pertenecen los cursos y cuerpos de agua, y ejercen una influencia directa sobre las condiciones de borde que orientan el diseño hidráulico de las estaciones de bombeo. Dado que a partir del límite de Línea de Ribera surge la propiedad de los particulares ribereños, es la jurisdicción municipal la que norma la ocupación del territorio y son los municipios de Resistencia/Barranqueras los responsables de los desagües pluviales.




Fig. 1. Ubicación de la estación de bombeo respecto a la laguna Rissione y las lagunas aportantes al cuerpo de ésta.

Ante la complejidad del esquema jurisdiccional planteado, resulta necesario encontrar la mejor solución técnica al problema para luego, una adecuada gestión entre provincia y municipio permita concretar las acciones para controlar los efectos de eventos pluviométricos extremos.

Para evaluar la eficiencia del sistema conformado por la cuenca urbana y la laguna, resulta indispensable llevar a cabo la simulación hidrológica de las seis subcuencas que integran el área de aporte a la laguna Rissione. Dicho análisis se realiza considerando un tiempo de recurrencia de 10 años, criterio adoptado por representar un nivel de riesgo aceptable y compatible con la normativa vigente. Este horizonte de diseño no solo permite estimar con mayor precisión la magnitud de los caudales generados bajo condiciones críticas de precipitación, sino que además constituye un parámetro de referencia para la planificación futura de la infraestructura hidráulica.

La selección de un período de retorno de 10 años adquiere especial relevancia, dado que establece las bases técnicas para proyectar los desagües pluviales que aún no han sido ejecutados dentro de la red urbana. En este sentido, la modelación hidrológica de las subcuencas no solo ofrece un diagnóstico cuantitativo sobre la respuesta hidrológica de la cuenca, sino que también aporta criterios para la jerarquización de obras, la identificación de sectores críticos y la definición de lineamientos de gestión integrada del drenaje urbano.

2. Materiales y métodos

El sistema hídrico de la Laguna Rissione, mostrado en Fig. 1, evacua los excedentes de un sector ubicado al este de Resistencia y oeste de Barranqueras, delimitado en líneas generales por la Diagonal Eva Perón al sur, el predio de la Guarnición Ejército Argentino y el Barrio La Fabril al sur oeste, calles internas del Barrio Golf Club y del predio del Chaco Golf Club por el oeste, el terraplén de defensa del río Negro en coincidencia con la Avenida Rissione al nor-este y calles internas de Villa Hortencia y Villa San Isidro por el este, conformando el territorio involucrado un área total de aporte de 516,62 hectáreas.

2.1. Delimitación de cuencas

En base a las características topográficas y a las modificaciones generadas por el entramado urbano, en especial el cuneteo de las calles, los conductos pluviales existentes y la ubicación de sumideros, se ha determinado que la Laguna Rissione, recibe actualmente los aportes de cinco (5) subcuencas, conformadas por el área de influencia de las Lagunas Golf (ex Negra), Blanca, La Liguria, Villa Concepción y Villa Hortencia ubicadas aguas arriba y que a través de conductos y alcantarillas descargan en la laguna Rissione, la cual a su vez tiene su propia área de aporte. En la Fig. 2 se presenta la delimitación de cuencas.

En la Tabla 1 se presenta la identificación de las subcuencas que pertenecen al sistema hídrico con sus áreas de aporte.

2.2. Usos actuales del suelo

La evaluación hidrológica del sistema de la laguna Rissione requiere el conocimiento en detalle del uso del suelo, a fin de caracterizar las condiciones de impermeabilidad y absorción de los distintos sectores integrantes de cada subcuenca, como elementos básicos para la determinación de la lluvia neta.

Se utilizó una imagen satelital CNES Airbus de marzo de 2024, obtenida de Google Earth, que se considera suficientemente clara y reciente para representar las condiciones requeridas. La imagen fue

procesada utilizando el programa QGIS versión 3.22.7 [4].

Tabla 2. Resumen de Áreas de aporte del Sistema Laguna Rissione.

Sistema lagunar	Subcuenca	Área (has)
Rissione	Golf	74.23
	Blanca	69.56
	La Liguria	83.00
	Villa Concepción	103.31
	Villa Hortencia	36.90
	Rissione	149.63
Área total		516, 62




Fig. 2. Subcuencas del sistema Laguna Rissione.

Para identificar los usos del suelo se utilizó el software ArcGIS Pro versión 2.5. Se empleó una metodología de clasificación no supervisada, seguida de una reclasificación supervisada.

Se utilizó la herramienta Iso Cluster Unsupervised Classification, configurada para generar 16 clases, a las cuales se les asignó un valor de uso del suelo según la siguiente categorización: 1) árboles, 2) pasto y 3) superficies impermeables. En esta última categoría se incluyeron calles pavimentadas, calles de tierra, piscinas, techos, veredas sin canteros y otras superficies con baja o nula infiltración.

Cabe destacar que las calles de tierra fueron consideradas impermeables, dado que la compactación ocasionada por el tránsito impide la absorción desde el punto de vista hidrológico.

Posteriormente, se utilizó la herramienta ReClassify para transformar las 16 clases iniciales en las 3 categorías mencionadas anteriormente. Este proceso permitió una mejor interpretación de los resultados, ajustándolos a las necesidades del estudio hidrológico.

Finalmente, se verificaron los resultados obtenidos de la clasificación supervisada, la cual arrojó valores coherentes con lo observado en la imagen satelital, tomando distintos sectores de control.

En la Fig. 3 se muestra un mapa del Sistema Rissione, con las áreas de laguna en celeste, las áreas con árboles en verde, las áreas con pasto en amarillo y las áreas impermeables en violeta.




Fig. 3. Clasificación de áreas de lagunas, árboles, pasto e impermeables.

2.3. Adopción de parámetros para la modelación hidrológica

Mediante el procesamiento de la información, se estimaron los valores a asignar en la modelación hidrológica a las abstracciones iniciales mediante la metodología de pérdidas del SCS (parámetro CN o Curva Número) [5], que permite determinar la lluvia neta que producirá el escurrimiento superficial en cada subcuenca. Asimismo, se pudo estimar la impermeabilidad de cada subcuenca, que es una herramienta auxiliar solicitada por el programa. El CN que solicita el programa HEC-HMS [6] es solo para la parte permeable, mientras que para el área impermeable se solicita únicamente el porcentaje respecto del área total de la cuenca.

En la Tabla 2 se muestran los parámetros hidrológicos adoptados: la impermeabilidad total y el CN para cada subcuenca, en las condiciones actuales y en la Tabla 3 se muestran los parámetros hidrológicos adoptados para las condiciones de diseño.

Tabla 2. Valores de Curva Número e Impermeabilidad del sistema Rissione, en las condiciones actuales.

Subcuenca	Curva Número (CN)	Impermeabilidad (%)	Subcuenca	Curva Número (CN)	Impermeabilidad (%)
Golf	56	45%	Villa Concepción	56	55%
Blanca	56	45%	Villa Hortencia	56	50%
La Liguria	56	50%	Rissione	56	42%

Tabla 3. Valores de Curva Número e Impermeabilidad del sistema Rissione, en las condiciones de diseño.

Subcuenca	Curva Número (CN)	Impermeabilidad (%)	Subcuenca	Curva Número (CN)	Impermeabilidad (%)
Golf	56	48%	Villa Concepción	56	58%
Blanca	56	48%	Villa Hortencia	56	57%
La Liguria	56	52%	Rissione	56	53%

2.4. Tratamiento estadístico de la precipitación

El estudio de la precipitación se basó en el análisis estadístico de registros pluviográficos de lluvias intensas, que para aplicaciones en el AMGR está sustentado en la información generada por las estaciones Colonia Benítez – INTA y Campus Resistencia-UNNE, comprendiendo el período 1960-2019 (60 años). La consistencia y cobertura espacial de esos registros garantiza la representatividad adecuada para las cuencas del sistema de la laguna Rissione.

En función de lo explicitado, se tomaron como base las Curvas Intensidad-Duración-Tiempo de Recurrencia (I-D-TR) que han sido aprobadas por la Administración Provincial del Agua del Chaco – APA mediante la Resolución N.º 1334/21 [7], y que se apoyan en la información mencionada inicialmente.

Se dispuso, asimismo, de la serie de Precipitación Máxima Diaria Anual de Resistencia, compilada por el Departamento de Hidráulica de la Facultad de Ingeniería (UNNE), para el período 1960-2023, similar a la longitud del registro utilizada para las actuales Curvas I-D-TR, de modo de obtener también los valores máximos precipitados en un día para los distintos escenarios de probabilidad requeridos.

La serie finalmente estudiada a través del análisis de frecuencia ha sido ordenada en forma cronológica para su tratamiento con el Programa AFMULTI [8], el cual utiliza siete (7) distribuciones de probabilidad teórica para ser ejecutadas a fin de estudiar la asignación de frecuencia y recurrencia.

Para proceder a la elección del modelo probabilístico que mejor se ajusta a la frecuencia experimental o real del conjunto de elementos de la serie, se aplicaron las pruebas de bondad de ajuste de Kolmogoroff-Smirnov y de Chi Cuadrado y se calcularon los Errores Cuadráticos Medios tanto en frecuencia (ECMF) como en variable (ECMV), confrontando cada distribución teórica con la experimental. Resultando la función Pearson como la que proporciona un mejor ajuste a las probabilidades reales.

2.5. Adopción de la tormenta de diseño

La tormenta de diseño y su período de retorno (TR) son elementos fundamentales para la obtención de los caudales aportantes por cada subcuenca, el primero ligado a la duración del evento, cuya distribución temporal se relaciona con el tiempo de concentración para el área de aporte considerada, y el segundo como condición de proyecto, que para el presente caso se ha fijado en 10 años de recurrencia.

Resulta de importancia aclarar que, si bien en el drenaje de las subcuencas en estudio se considera finalmente el escurrimiento que generan los excedentes de aguas de lluvia, se utiliza la frecuencia de las precipitaciones como medida del grado de riesgo ante la ausencia de un récord estadísticamente tratable de valores de escurrimiento. Por lo tanto, se supone que la frecuencia de los escurrimientos y de las lluvias que los generan son las mismas.

Aplicando el método de los Bloques Alternos [5] y centrando su valor máximo en el tiempo de concentración del sistema modelado, se han determinado las alturas de precipitación con intervalos de 5 minutos para una duración total de 9 horas, que es el tiempo en que las curvas I-D-TR determinan la caída de la lluvia total diaria, cuyo valor es de 160,8 mm para la recurrencia de 10 años, como se muestra en la Fig. 4. La intensidad máxima de este evento se produce en el intervalo de 40 a 45 minutos y su valor es de 168 mm/h.




Fig. 4. Tormenta de diseño para un TR = 10 años, $\Delta t = 5$ minutos y $T_d = 9$ horas.

2.6. Tormentas de verificación

Se realizó una verificación del funcionamiento de la estación de bombeo, ante la ocurrencia de eventos extremos sobre el área de aportes identificada, con tiempos de recurrencia de 25 y 50 años, de modo tal que la operación del equipamiento a instalar permita controlar el nivel de la Laguna sin que alcance la “Línea de advertencia”, compatible con una situación de riesgo severo. Como se ha mencionado al inicio, la cota de la línea de advertencia es de 47,29 m MOP.

En la Fig. 5 se muestra el hietograma del evento con TR= 25 años, que alcanza un total de 188,6 mm con una duración de 6 hr y 35 min, con intervalo de ocurrencia de la intensidad máxima entre los 40-45min y valor de 193,2 mm/hr.

En la Fig. 6 se muestra el hietograma del evento con TR= 50 años, que alcanza un total de 207,5 mm con una duración de 6 hr y 35 min, con intervalo de ocurrencia de la intensidad máxima entre los 40-45min y valor de 205,2 mm/hr.

2.7. Modelación hidrológica del sistema

Para la modelación hidrológica del sistema Rissione se adoptó el modelo/programa HEC-HMS, desarrollado por el Centro de Ingeniería Hidrológica del Cuerpo de Ingenieros del Ejército de los

EEUU [6], de acceso gratuito y que es permanentemente actualizado, con el objeto de representar el comportamiento de la cuenca ante un evento de diseño con $TR = 10$ años.




Fig. 5. Tormenta de diseño para un $TR = 25$ años, $\Delta t = 5$ minutos y $T_d = 6$ horas, 35 minutos




Fig. 6. Tormenta de diseño para un $TR = 50$ años, $\Delta t = 5$ minutos y $T_d = 6$ horas, 35 minutos

En la Fig. 7 se presenta el esquema de modelación adoptado para la simulación hidrológica con HEC-HMS.

Los caudales presentados en la Tabla 4, son generados por las subcuencas hacia la descarga de las lagunas. A partir de estos datos, se realizará la propagación hidráulica en los conductos y alcantarillas de vinculación hacia la laguna Rissione. Se incluyen los datos de caudal pico, tiempo al pico y el volumen de escurrimiento. Con respecto a la situación de diseño ($TR = 10$ años) el volumen total generado por las cinco subcuencas de aporte y el de Rissione propiamente dicha, alcanza un valor de 549.800 m^3 , lo que equivale a una lluvia neta promedio sobre toda el área de estudio de $106,4 \text{ mm}$. En esas condiciones, el Coeficiente de Escorrentía que produce este evento resulta de un valor igual a $0,66$.




Fig. 7. Esquema de modelación hidrológica adoptado con HEC-HMS.

Tabla 4. Valores característicos de los hidrogramas generados por las subcuencas para TR 10 años.

TR 10 AÑOS			
Cuencas	Caudal Pico (m ³ /s)	Tiempo al pico (hs:min)	Volumen de escurrimiento (m ³)
Golf - Negra	6.7	01:20:00	74900
Blanca	5.8	01:25:00	70300
La Liguria	7.5	01:20:00	87600
Concepción	9.5	01:25:00	116200
Hortencia	4.4	01:10:00	41100
Rissione	11.2	01:35:00	159700

En la Fig. 8 se muestra la evolución del hidrograma generado en la laguna Rissione, producto de los aportes propios de la misma, que por ser la de mayor tamaño de cuenca genera los mayores volúmenes y caudales asociados.




Fig. 8. Hidrograma generado por el área de aporte propio de la laguna Rissione para TR= 10 años.

2.8. Modelación hidráulica del sistema

Para transitar los hidrogramas de escurrimiento directo generados a partir de la tormenta de diseño de 10 años, se empleó un modelo tipo “onda dinámica”, concretamente el Storm Water Management Model (SWMM), desarrollado por la agencia ambiental EPA de los Estados Unidos, en su versión 5.2 [9].

La modelación hidráulica, bajo dicho entorno, incluyó la laguna Rissione, y las cinco lagunas que a esta aportan: i) Villa Hortencia, ii) Villa Concepción, iii) La Liguria, iv) Golf y v) Blanca).

Por tanto, el esquema de modelación incluyó seis unidades de almacenamiento (simulando el funcionamiento hidráulico de las lagunas) que reciben los caudales de ingreso de sus correspondientes cuencas (cargados como Inflows).

La descarga de la laguna Rissione se consideró en dos escenarios. El primero considerando en el que por los altos niveles del río Negro, solo pueden erogarse los volúmenes excedentes pluviales de la laguna mediante bombeo. El segundo, considerando una descarga por gravedad a partir de tener las compuertas abiertas. En esta etapa se detallan sólo las simulaciones relacionadas a la descarga por bombeo.

El esquema de modelación hidráulico desarrollado para este proyecto es el ilustrado en la Fig. 9.




Fig. 9. Modelación hidráulica de la laguna Rissione.

2.9. Curvas de almacenamiento

Las superficies de anegamiento surgieron de las curvas de nivel trazadas con la nivelación topográfica realizada al efecto, y fueron usadas como datos en la modelación hidráulica. Al respecto el nivel inicial usado en la Laguna Rissione fue de 46,56 m (20 cm por debajo de la Línea de Ribera),

lo que supone un prebombeo previo antes del inicio del evento simulado. Los niveles de agua de cada laguna se detallan en la Tabla 5.

Tabla 5. Niveles iniciales de agua de cada laguna usados en la simulación

Laguna	Nivel mínimo (m, MOP)	Tirante inicial (m)	Nivel de agua (m, MOP)
Rissione	44.806	1.754	46.56
Blanca	46	0.89	46.89
Liguria	45.6	1.61	47.21
Hortensia	46.2	1.09	47.29
Concepción	46.1	1.31	47.41
Golf	46.2	1.44	47.64

2.10. Conductos de Vinculación

Las vinculaciones entre las lagunas se modelaron como alcantarillas considerando siempre las dimensiones y las cotas de invertido mensuradas en campo (Tabla 6).

Tabla 6. Dimensiones de los conductos existentes que permiten la vinculación entre lagunas

Ubicación	Tipo	L (m)	H (m)	Diám. (m)	J (m)	C.D.
Vinculación Negra - Blanca	Tubo H°	-	-	0.80	9.00	46.42
Vinculación Blanca - Rissione	Tubo H°	-	-	0.80	100	45.71
Vinculación La Liguria - Rissione	Tubo H°	-	-	1.20	19.00	45.71
	Tubo H°	-	-	0.90	19.50	45.70
Vinculación Concepción - Rissione	Tubo H°	-	-	1.00	12.00	46.36
	Tubo H°	-	-	1.10	12.00	46.31
Vinculación Hortencia - Rissione	Tubo H°	-	-	0.60	8.00	46.27

2.11. Equipamiento de Bombeo y Regla de operación

Respecto al equipamiento de bombeo, la capacidad de este surgió de una "solución de compromiso" entre volumen - área del reservorio - tiempo de permanencia del agua y número y potencia de los equipos. La capacidad máxima del equipo de bombeo simulado en la modelación fue de 7,5 m³/s, integrado por 5 bombas, instaladas en paralelo, de 1,5 m³/s de capacidad cada una. El funcionamiento de las bombas se propone en forma escalonada en concordancia con los niveles alcanzados en el reservorio (Tabla 7).

Tabla 7. Regla de operación para la estación de bombeo de laguna Rissione

Cota de inicio de bombeo (m, MOP)	Cota de finalización de bombeo (m, MOP)	Caudal (m ³ /s)	Bomba
46,56	46,61	1,500	BG N° 1
46,61	46,63	3,000	BG N° 2
46,66	46,65	4,500	BG N° 3
46,71	46,67	6,000	BG N° 4
46,76	46,69	7,500	BG N° 5

3. Resultados y Discusión

3.1. Simulación hidráulica del sistema para la situación de diseño

En la Fig. 10 se ilustra el funcionamiento del reservorio de bombeo para un evento de 10 años de recurrencia. A tal efecto, la simulación muestra caudales máximos de ingreso de 15,83 m³/s, en tanto que el reservorio presenta un nivel máximo de agua de 46,96 m.




Fig. 10. Funcionamiento del reservorio de bombeo – TR = 10 años

3.2. Simulación hidráulica del sistema para eventos extremos

En la Fig. 11 se ilustra el funcionamiento del reservorio de bombeo para un evento de 25 años de recurrencia. A tal efecto, la simulación muestra caudales máximos de ingreso de 18,91 m³/s, en tanto que el reservorio presenta un nivel máximo de agua de 47,15 m.




Fig. 11. Funcionamiento del reservorio de bombeo – TR = 25 años

En la Fig. 12 se ilustra el funcionamiento del reservorio de bombeo para un evento de 50 años de recurrencia. A tal efecto, la simulación muestra caudales máximos de ingreso de 20,49 m³/s, en tanto que el reservorio presenta un nivel máximo de agua de 47,26 m.




Fig. 12. Funcionamiento del reservorio de bombeo – TR = 50 años

En la Tabla 8 se indican los valores de niveles de agua (Nmax) en la laguna Rissione, el caudal pico de ingreso a esta (Qmax) y el tiempo en que perdura el máximo de bombeo de 7,5 m³/s (Tbmax) arrojados por el modelo para los distintos escenarios de simulación.

Tabla 8. Niveles de agua y caudales de Ingreso máximos de la laguna Rissione

Tiempo de recurrencia	Nmax (m, MOP)	Qmax (m ³ /s)	Tbmax (hs)
10 años	46,96	15,83	12,92
25 años	47,15	18,91	18,25
50 años	47,26	20,49	20,51

4. Conclusiones

El funcionamiento hidrológico de las lagunas y su relación con las obras de control del escurrimiento que reciben y deben volcar hacia el río Negro, parte de la base de conocer los valores de altura de agua entre los que oscila cada laguna en los distintos ciclos hidrológicos.

Del análisis de los hidrogramas de entrada y salida, así como de la evolución del volumen almacenado en la laguna Rissione, se determinó que, para la situación de diseño, el caudal máximo de ingreso es de 15,83 m³/s, mientras que el caudal de salida por bombeo alcanza los 7,50 m³/s. El nivel máximo de almacenamiento en el reservorio se estableció en 46,96 m, valor que implica la operación simultánea de las cinco bombas previstas en el diseño de la estación de bombeo del sistema proyectado y que se mantiene por debajo de la “Línea de Advertencia” definida por la APA, cumpliendo así con la premisa de diseño.

La revisión del grado de impermeabilidad actual y futura de cada subcuenca, y la adopción del parámetro CN fueron factores de importancia para una estimación verosímil de caudales máximos y

volúmenes de aporte, los que inciden directamente en la capacidad de evacuación de la obra de control de la laguna receptora Rissione. Para la estimación de los valores de impermeabilidad futura se tuvo en cuenta los límites que imponen las restricciones municipales vigentes, considerando una interacción de obras y medidas no estructurales. Este aspecto del análisis se ha basado en los límites impuestos a la impermeabilidad de los lotes urbanos en todo el ejido municipal de Resistencia y a la definición de “distritos” con diferentes tipos de usos, algunos de ellos como “Urbanización Especial de Asentamientos” (UEA) por tratarse de áreas inter lagunares [10].

La definición de las cotas de línea de ribera y riesgo hídrico de cada laguna, y los parámetros de diseño de la obra de control, serán apropiados para el funcionamiento de los niveles de esas lagunas, en la medida que el Municipio local y la Provincia respeten esos niveles, con el control de la impermeabilidad ya mencionado y de los asentamientos en los bordes de estos espejos de agua, teniendo en cuenta el contexto de muy baja energía del relieve del AMGR.

La verificación de las condiciones de funcionamiento para eventos extremos, se consideró satisfactoria, dada la criticidad de los eventos de diseño utilizadas.

Las lagunas cumplen un rol fundamental desde la perspectiva de la Ecohidrología, al brindar servicios ambientales asociados a su función como retardadores del escurrimiento. Esta capacidad requiere comprender la interacción entre las características geomorfológicas, el uso del suelo y el agua, lo que permite regular el escurrimiento superficial, atenuar los picos de crecida y contribuir a la prevención de inundaciones urbanas.

Referencias

- [1] SUPCE-AFIN (1998), Plan de manejo pluvial para la cuenca inferior del río Negro dentro del Área Metropolitana del Gran Resistencia.
- [2] APA-AFIN (2001), Línea de ribera de lagunas ubicadas en el Sistema Hídrico del río Negro
- [3] Administración Provincial del Agua (APA) – Chaco – Argentina, Resolución N° 303/17
- [4] QGIS Development Team. (2022). QGIS Geographic Information System (Versión 3.22.7) [Software]. QGIS Association. <https://qgis.org>
- [5] Ven Te Chow, Maidment, D. R., Mays, L. W. (1994). Hidrología Aplicada. Mc Graw Hill Interamericana S. A., Santa Fé de Bogotá, Colombia.
- [6] U.S. Army Corps of Engineers, Hydrologic Engineering Center. (2021). HEC-HMS Hydrologic Modeling System: User's Manual, version 4.9. Davis, CA: Institute for Water Resources, Hydrologic Engineering Center.
- [7] Administración Provincial del Agua (APA) – Chaco – Argentina, Resolución N° 1334/21
- [8] Paoli, C., Bolzicco, J., Cacik, P. (1991). Análisis de frecuencia para determinación de la crecida de diseño. Facultad de Ingeniería y Ciencias Hídricas, Universidad Nacional del Litoral. Santa Fe, Argentina.
- [9] Rossman L. 2010. Storm Water Management Model –User's Manual (Version 5.0). Water Supply and Water Resources Divison. National Risk Management Research Laboratory. Cincinnati.
- [10] Consejo Municipal de Resistencia (2021), “Distritos de la ciudad de Resistencia”.Ordenanza N° 13756 del 21/12/2021.

Predicción de Costos y Plazos en Proyectos de Construcción: Un enfoque Basado en Inteligencia Artificial

Miryan R. Puchini^{1,*} , Nancy B. Ganz^{1,2} , Yolanda E. Zado¹ 

¹ Universidad Nacional de Misiones, Facultad de Ingeniería, Misiones, Argentina.

² Universidad Nacional de Misiones, Facultad de Ciencias Exactas Químicas y Naturales, Instituto de Materiales de Misiones, Misiones, Argentina.

e-mails: miryanpuchini@fio.unam.edu.ar, nancy.ganz@fio.unam.edu.ar, yolandazado@gmail.com

Resumen

La estimación precisa de tiempo y costos es fundamental para la planificación y gestión eficiente de los proyectos de construcción, ya que la incertidumbre o información imprecisa puede generar sobrecostos, demoras y un uso ineficiente de los recursos. Los métodos tradicionales presentan limitaciones en contextos dinámicos y complejos. En este marco, estudios recientes demuestran que la aplicación de modelos de Inteligencia Artificial y aprendizaje automático mejora significativamente la precisión predictiva al manejar la variabilidad de los datos. Este trabajo se basa en una revisión bibliográfica crítica y propone el uso de modelos de IA como alternativa a los enfoques tradicionales para optimizar la estimación de tiempos y costos. Los resultados indican que modelos como Extra Trees y XGBoost alcanzan coeficientes de determinación (R^2) superiores a 0,92 en la predicción de costos, mientras que la estimación de tiempos depende fuertemente de la calidad de los datos disponibles. Se concluye que la IA constituye una herramienta estratégica para mejorar la planificación y la toma de decisiones en el sector.

Palabras Clave – Proyectos de construcción, Estimación de costos, Predicción de duración, Inteligencia artificial, Aprendizaje automático.

Abstract

Accurate time and cost estimation is fundamental for the efficient planning and management of construction projects, as uncertainty or imprecise information can lead to cost overruns, delays, and inefficient resource allocation. Traditional methods exhibit limitations in dynamic and complex contexts. Within this framework, recent studies demonstrate that the application of Artificial Intelligence (AI) and Machine Learning models significantly improves predictive accuracy by handling data variability. This paper is based on a critical literature review and proposes the use of AI models as an alternative to traditional approaches to optimize time and cost estimation. The results indicate that models such as Extra Trees and XGBoost achieve coefficients of determination (R^2) exceeding 0.92 in cost prediction, while time estimation remains heavily dependent on the quality of available data. It is concluded that AI constitutes a strategic tool for enhancing planning and decision-making within the sector.

Keywords – Construction projects, Cost estimation, Duration prediction, Artificial intelligence, Machine learning.

1. Introducción

La precisión en la estimación de tiempo y costos constituye un factor crítico para la planificación y la gestión eficiente de los proyectos de construcción. La presencia de incertidumbres o de información imprecisa en estas etapas puede derivar en sobrecostos, demoras, desvíos en los cronogramas y un uso ineficiente de los recursos, afectando negativamente a todas las partes involucradas.

Tradicionalmente, estas estimaciones se han realizado mediante métodos descriptivos, conceptuales o estadísticos, los cuales presentan limitaciones en entornos altamente dinámicos y complejos. En este contexto, investigaciones recientes han demostrado que la incorporación de modelos de Inteligencia Artificial (IA) y aprendizaje automático (*Machine Learning*, ML por sus siglas en inglés) mejora significativamente la precisión predictiva, al emplear técnicas avanzadas como *Random Forest*, *K-Nearest Neighbors*, SVM o redes neuronales, logrando resultados más sólidos frente a la variabilidad de los datos.

Este trabajo se fundamenta en una revisión bibliográfica crítica y propone el desarrollo de modelos basados en IA como alternativa eficaz frente a los métodos tradicionales, con el objetivo de optimizar la estimación de tiempo y costos en proyectos de construcción, reduciendo la incertidumbre y fortaleciendo la toma de decisiones desde etapas tempranas.

2. Marco teórico

2.1. Factores e incertidumbres en los proyectos de construcción

La finalización en tiempo y forma de los proyectos de construcción depende en gran medida de estimaciones precisas de tiempo y costo, dos parámetros que se ven fuertemente afectados por incertidumbres inherentes al entorno constructivo. Estas incertidumbres, si no se gestionan adecuadamente, impactan negativamente en la planificación, ejecución y control del proyecto, por lo que es crucial desarrollar estrategias eficaces para su identificación y mitigación.

En el trabajo consultado han subrayado la importancia de incorporar la incertidumbre en los modelos de programación de obras, mediante el uso de herramientas avanzadas como algoritmos de IA y técnicas estadísticas. Se destaca, además, la influencia de factores como la gestión deficiente del sitio, la escasez de recursos financieros y las fallas comunicacionales, los cuales contribuyen a desviaciones significativas en los cronogramas y presupuestos.

Han abordado estas problemáticas a través de modelos matemáticos capaces de cuantificar el impacto de los riesgos sobre la duración y los costos. El tratamiento explícito de distintos tipos de incertidumbre, ya sea a través de estudios empíricos, curvas S de riesgo o modelos predictivos, han demostrado mejorar considerablemente la precisión de las estimaciones.

Asimismo, evidencian que el sistema de entrega del proyecto influye directamente en la estimación del tiempo, siendo objeto de análisis comparativos, evaluaciones de riesgo y estudios de caso, especialmente en proyectos de vivienda pública. La adopción de enfoques como el diseño-construcción o la entrega integrada de proyectos ha mostrado ventajas frente a contextos de alta complejidad e incertidumbre, al facilitar una mejor coordinación entre las partes y una mayor adaptabilidad frente a eventos no previstos.

Finalmente mencionan, sobre nuevas líneas de investigación que abordan temas emergentes que afectan la entrega de proyectos, como la ciberseguridad en entornos digitales de construcción o la incorporación de indicadores de sostenibilidad en los procesos de planificación y ejecución, ampliando así la visión tradicional de riesgos hacia un enfoque más integral y actual [1].

Respecto a los factores que inciden en los resultados del proyecto, la literatura los clasifica en dos categorías: Factores Cruciales, aquellos que ayudan a prevenir disputas y retrasos, por ejemplo, la estimación precisa de la duración de cada actividad. Factores Críticos de Éxito (CSF, por sus siglas en inglés), que garantizan el éxito en la planificación y permiten una gestión eficiente de los recursos. Algunos CSF identificados son: tamaño y complejidad del proyecto, condiciones del

sitio, tipo de obra, ubicación geográfica, disponibilidad de recursos y materiales, productividad de la mano de obra, modificaciones en el diseño, cambios normativos y condiciones climáticas imprevistas.

Se han identificado hasta 48 factores causales de retrasos y 38 factores de sobre costos, clasificados en cuatro categorías: causas atribuibles al contratista, al consultor, al cliente y causas externas. Estos estudios constituyen un marco valioso, pero es necesario profundizar en su análisis para desarrollar soluciones viables y evaluar su eficacia en la práctica, con el objetivo de asegurar la ejecución exitosa de los proyectos de construcción [2].

2.2. Métodos tradicionales para estimar tiempo y costo

Los proyectos de construcción, especialmente los del tipo residencial, requieren estimaciones precisas de la duración de cada actividad debido a los diversos riesgos e incertidumbres que afectan el tiempo total de finalización. Tradicionalmente, estas estimaciones se realizan mediante técnicas clásicas de planificación y gestión de proyectos, entre las que se destacan:

- El Método del Camino Crítico (CPM, por sus siglas en inglés *Critical Path Method*) es un enfoque determinista ampliamente utilizado en la planificación de proyectos de construcción. Su principal ventaja radica en la simplicidad de su implementación, ya que permite identificar la duración mínima del proyecto a partir de un análisis lineal. Sin embargo, una de sus limitaciones más significativas es que considera una única duración fija para cada actividad, sin incorporar la variabilidad ni los factores de incertidumbre. Como resultado, el cronograma generado puede no reflejar fielmente las condiciones reales del proyecto [3].
- La Técnica de Evaluación y Revisión de Programas (PERT, por sus siglas en inglés *Program Evaluation and Review Technique*), introduce un enfoque probabilístico al considerar tres estimaciones de duración (optimista, más probable y pesimista) para cada actividad. Este método permite incorporar la incertidumbre inherente a los proyectos, generando una planificación más realista y detallada, al tiempo que facilita la visualización de tareas y sus respectivas dependencias [4].
- El Método de Simulación de Montecarlo (MCS) es una técnica estadística avanzada que permite simular múltiples escenarios posibles en función de variables aleatorias. Su aplicación no se limita solo a la estimación de tiempos, sino que también considera restricciones de costo y riesgos asociados, lo cual proporciona un marco más robusto para la toma de decisiones estratégicas durante la planificación y ejecución del proyecto [5].

Además, en el estudio [5] se ejemplifica la aplicabilidad de estos métodos tradicionales en un proyecto de construcción de una vivienda con 24 actividades planificadas. Al aplicar CPM, se obtuvo una duración estimada de 63 días. En contraste, al emplear PERT y MCS con un nivel de confianza del 95 %, las duraciones proyectadas fueron de 70 y 79 días, respectivamente. Estos resultados evidencian que los métodos probabilísticos, como PERT y MCS, ofrecen cronogramas más ajustados a la realidad al contemplar los riesgos e incertidumbres propios de los proyectos de construcción.

Estos resultados demuestran que los métodos probabilísticos constituyen herramientas valiosas para los gerentes de proyectos, permitiéndoles programar obras de construcción residencial

considerando los riesgos e incertidumbres inherentes. Si bien PERT y MCS son útiles para la elaboración de cronogramas más realistas, su precisión está directamente condicionada por la calidad de las variables de entrada y por la fidelidad del modelo que representa al proyecto. Las deficiencias de estos modelos, están en que las estimaciones de duración de las actividades no son precisas, perdiendo confiabilidad en sus resultados. Es importante destacar que ni PERT, ni MCS proporcionan soluciones definitivas por sí mismos, sino que actúan como herramientas de apoyo para anticipar el comportamiento del proyecto en escenarios inciertos y la toma de decisiones finales recae en el gerente de proyecto, quien debe realizar una evaluación integral de las condiciones particulares de la obra antes de adoptar una estrategia de planificación adecuada [6].

2. 3. Modelación de Información de la Construcción

Como se ha mencionado previamente, los métodos tradicionales, deterministas o probabilísticos, utilizados en la planificación de proyectos de construcción presentan limitaciones significativas, especialmente en lo que respecta a la integración de información multidimensional y la actualización en tiempo real.

En respuesta a estas limitaciones, el Modelado de Información de la Construcción (*Building Information Modeling*, BIM) se posiciona como una tecnología disruptiva que ha transformado la forma en que se planifican, diseñan, ejecutan y gestionan los proyectos. BIM opera dentro de un entorno colaborativo e integrado, facilitando la centralización de datos y mejorando la coordinación entre los distintos actores del proceso constructivo.

En la actualidad, numerosos profesionales del sector de la arquitectura, la ingeniería y la construcción (AEC) reconocen un cambio de paradigma marcado por la convergencia entre BIM y la IA. Esta integración promueve nuevas oportunidades para optimizar el rendimiento organizacional, mejorar la toma de decisiones y aumentar la eficiencia en la entrega de proyectos, especialmente mediante el aprovechamiento de grandes volúmenes de datos secundarios generados durante el ciclo de vida del proyecto.

BIM puede entenderse a partir de sus dos componentes fundamentales: por un lado, como una representación digital compartida de un activo físico, que constituye una base confiable para la toma de decisiones a lo largo de todo su ciclo de vida, desde su concepción hasta la demolición; y por otro lado, como un proceso basado en modelos 3D inteligentes, que proporciona a los profesionales del sector AEC las herramientas y la información necesarias para planificar, diseñar, construir y operar edificaciones e infraestructuras de manera más eficiente.

Un concepto clave de BIM es su estructura en una serie de capas interconectadas, cada una de las cuales aporta niveles adicionales de información y funcionalidad al modelo, enriqueciendo su capacidad para representar y gestionar el ciclo de vida de un proyecto de construcción. Comienza con la capa geométrica (3D), que representa la forma y ubicación de los elementos del edificio, y se complementa con la capa semántica, que agrega propiedades y atributos técnicos. La capa topológica define relaciones funcionales entre componentes, mientras que las capas temporales (4D) y costos (5D) incorporan planificación y estimación financiera. A esto se suman la capa de sostenibilidad (6D), que evalúa el impacto ambiental, la gestión de instalaciones (7D), que abarca el mantenimiento y uso eficiente del edificio, y finalmente la integración con IoT, que conecta sensores y dispositivos inteligentes para monitoreo en tiempo real.

2.3.1. Rol de la IA en BIM

La integración entre la IA y BIM está dando lugar a modelos inteligentes capaces de procesar grandes volúmenes de datos en tiempo real, reconocer patrones y proponer soluciones optimizadas en todo el ciclo de vida del proyecto. Esta sinergia ha impulsado el desarrollo de múltiples aplicaciones especializadas, acompañadas de herramientas concretas en el mercado:

- Diseño paramétrico y generativo: Autodesk Forma, permite generar múltiples opciones de diseño en función de datos del sitio y normativas; Project Refinery, aplica IA para explorar alternativas según objetivos específicos.
- Análisis energético y sostenibilidad: Autodesk Insight, integrado con Revit, analiza el rendimiento energético del edificio; Tally, complemento de Revit, calcula el impacto ambiental de los materiales.
- Detección de conflictos y coordinación: Navisworks, con capacidades de IA, identifica conflictos y sugiere resoluciones basadas en datos históricos.
- Simulación de construcción y planificación (4D): Synchro, permite simular escenarios, optimizar cronogramas y prever retrasos.
- Cumplimiento normativo automatizado: UpCodes AI, vinculado con Revit, verifica automáticamente la conformidad con códigos de edificación.
- Evaluación de riesgos del proyecto: Kognoz, aplica ML para anticipar riesgos combinando datos BIM e históricos.
- Gestión inteligente de instalaciones (7D): IBM TRIRIGA, integrado con BIM, optimiza el mantenimiento, la gestión de activos y el uso eficiente del espacio.
- Modificaciones de diseño en tiempo real: Revit con IA, puede sugerir cambios basados en costos, rendimiento y regulaciones.

La fusión entre IA y BIM no solo mejora la eficiencia operativa, sino que redefine la forma en que se conciben, construyen y mantienen los entornos construidos. Las aplicaciones actuales ya impactan en áreas clave como diseño generativo, análisis de sostenibilidad, planificación 4D, gestión de riesgos y mantenimiento predictivo.

Las investigaciones apuntan al desarrollo de algoritmos de IA más robustos, la incorporación de computación cuántica, técnicas de aprendizaje federado, IA explicable, biomimética, blockchain, y gemelos digitales inteligentes aplicados a ciudades. Este ecosistema tecnológico promete transformar radicalmente la industria de la AEC, facilitando la creación de entornos más sostenibles, resilientes e inteligentes [7].

De lo expuesto se desprende que la implementación efectiva de la metodología BIM, especialmente en combinación con herramientas de IA, requiere la utilización de múltiples softwares especializados que abordan distintas dimensiones del proyecto (diseño, análisis energético, planificación, gestión de riesgos, mantenimiento, entre otros). Esta multiplicidad de plataformas, muchas veces desarrolladas por distintos proveedores y con niveles variables de interoperabilidad, genera una fragmentación de la información. Como resultado, no es posible disponer de una base de datos única y centralizada que contenga de forma integrada todos los datos

del proyecto. Esta dispersión dificulta la trazabilidad completa, la sincronización entre disciplinas y la aplicación de modelos de análisis globales basados en datos unificados.

2.4. Automatizar las estimaciones del tiempo y costo de un proyecto de construcción

En disciplinas ajenas a las Ciencias de la Computación, los términos Inteligencia Artificial (IA), aprendizaje automático o ML, y aprendizaje profundo o Deep Learning (DL, por sus siglas en inglés) suelen utilizarse de manera indistinta, especialmente en contextos comerciales. Sin embargo, desde una perspectiva técnica y académica, presentan diferencias sustanciales que es importante esclarecer (ver Fig. 1).

La IA abarca el conjunto de técnicas que permiten a las máquinas imitar capacidades cognitivas humanas, como el razonamiento, la toma de decisiones, el reconocimiento de patrones o el procesamiento del lenguaje. El ML constituye un subconjunto de la IA, que se enfoca en desarrollar algoritmos capaces de aprender a partir de datos, identificar patrones y realizar predicciones sin ser explícitamente programados para cada tarea específica. Algunos algoritmos de ML utilizados para estimaciones incluyen la regresión lineal, los árboles de decisión y los métodos basados en vecinos más cercanos (*K-Nearest Neighbors* por sus siglas en inglés KNN). El aprendizaje profundo es un subconjunto dentro del ML que se basa en arquitecturas de redes neuronales artificiales compuestas por múltiples capas de procesamiento. Estas redes permiten modelar relaciones no lineales complejas y extraer representaciones jerárquicas de los datos, mejorando el rendimiento en tareas como el reconocimiento de imágenes, el procesamiento de lenguaje natural y la predicción de variables en contextos de alta dimensionalidad, siendo eficaz en contextos donde los datos son masivos y no estructurados [8].




Fig. 1. Taxonomía IA [9].

Diversas investigaciones han evidenciado que la integración de modelos de inteligencia artificial con técnicas estadísticas mejora significativamente la precisión en la estimación de costos y plazos en proyectos de construcción. Se han aplicado algoritmos de aprendizaje automático como

Máquinas de Vectores de Soporte (SVM), Bosques Aleatorios, Naive Bayes y Redes Neuronales Artificiales (ANN), superando las limitaciones de métodos tradicionales como PERT, CPM y simulación de Montecarlo.

Entre los enfoques más prometedores destacan los modelos híbridos, que combinan distintos algoritmos para aprovechar sus fortalezas individuales, logrando mejoras sustanciales en la estimación, con errores MAPE (por sus siglas en inglés *Mean Absolute Percentage Error*) reportados inferiores al 5 % en costos y al 8 % en tiempo. Además, se ha incorporado la incertidumbre como variable crítica, considerando tanto componentes aleatorios como epistémicos, lo que permite una planificación más robusta y adaptativa.

En el ámbito del aprendizaje profundo, las Redes Neuronales Convolucionales (CNN) han mostrado potencial para estimar duraciones a partir de datos visuales o topográficos, mientras que las Redes Neuronales Recurrentes (RNN) destacan por su capacidad para modelar dependencias temporales y patrones secuenciales en actividades de obra. Estos avances posicionan a las arquitecturas neuronales, especialmente en configuraciones híbridas, como herramienta clave en la transformación digital del sector AEC, permitiendo anticipar desviaciones, reducir la incertidumbre y optimizar la planificación desde etapas tempranas del proyecto [10].

Una investigación reciente abordó la comparación entre algoritmos de aprendizaje automático y métodos tradicionales para predecir la duración de proyectos de construcción, utilizando datos recolectados mediante encuestas a organizaciones del sector. Se evaluaron modelos como Redes Neuronales Artificiales (NN), *Random Forest* (RF), Máquinas de Vectores de Soporte (SVM), *K-Nearest Neighbors* (KNN) y árboles de regresión (CART), implementados en R con la librería *caret*.

Los resultados indicaron que KNN fue el modelo más preciso, con un RMSE (por sus siglas en inglés *Root Mean Square Error*) de 81 días y un R^2 de 0,97, seguido de cerca por RF. En contraste, las redes neuronales mostraron bajo rendimiento debido a limitaciones en el tamaño del conjunto de datos y la selección de variables. El estudio concluye que RF y KNN ofrecen alta precisión para proyectos públicos, pero destaca la necesidad de incorporar más datos y variables contextuales para mejorar la robustez de modelos más complejos, como los de aprendizaje profundo [11].

2.5. Modelos predictivos basados en árboles de decisión

Si bien el avance de la IA y del ML ha impulsado el desarrollo de modelos predictivos de alta precisión aplicables a múltiples dominios, incluyendo la industria de la construcción; los algoritmos basados en árboles de decisión constituyen una de las familias más utilizadas por su capacidad para modelar relaciones no lineales y manejar variables heterogéneas. Entre ellos, los modelos *Random Forest* y *Extremely Randomized Trees* (ExtraTrees) se destacan por su robustez ante ruido y su estabilidad frente al sobreajuste, al combinar múltiples árboles entrenados sobre subconjuntos aleatorios de los datos. [12]. Estudios recientes evidencian que las variantes modernas de estos algoritmos, como SPLDExtraTrees, logran mejorar la generalización mediante mayor aleatorización en los puntos de corte. Asimismo, investigaciones comparativas demuestran que los métodos de ensamble basados en árboles —como *Random Forest*, ExtraTrees y BART— presentan un excelente equilibrio entre precisión y explicabilidad en entornos con alta incertidumbre [13].

Dentro de los modelos de *boosting*, XGBoost y LightGBM son ampliamente reconocidos por su capacidad para optimizar tanto el rendimiento como la eficiencia computacional. XGBoost

emplea técnicas de regularización y poda que reducen el error de generalización, mientras que LightGBM introduce métodos de muestreo y compresión de histogramas que aceleran el entrenamiento sin pérdida significativa de precisión. Aplicaciones recientes confirman la efectividad de XGBoost en la predicción de variables económicas y de ingeniería, superando a modelos lineales tradicionales. En paralelo, la literatura también destaca el uso de descenso estocástico del gradiente (SGD) como método de optimización eficaz para modelos lineales y redes neuronales en contextos de grandes volúmenes de datos [14].

Más recientemente, las herramientas de AutoML han permitido automatizar el proceso de selección de modelos y ajuste de hiperparámetros. En particular, FLAML (*Fast Lightweight AutoML*) propone un enfoque eficiente y de bajo costo computacional que prioriza la precisión en escenarios con recursos limitados, mostrando resultados competitivos frente a pipelines manuales. En el ámbito específico de la construcción, diversos estudios de revisión confirman que los algoritmos de aprendizaje automático, en especial los modelos de ensamble, han sido los más utilizados para predecir costos, duraciones y productividad de obra, destacando su potencial para reducir la incertidumbre y optimizar la toma de decisiones [15].

3. Materiales y métodos

Este estudio adopta un enfoque basado en el flujo de trabajo típico del aprendizaje automático (ML), ampliamente utilizado por empresas tecnológicas líderes como Amazon, Google y Microsoft. El proceso se estructura en tres etapas principales: tratamiento de los datos, modelado e implementación (ver Fig. 2).




Fig. 2. Flujo de trabajo ML [16].

3.1. Tratamiento de los datos y entrenamiento del mejor modelo

El éxito de cualquier modelo de ML depende en gran medida de la calidad de los datos. Dado que no fue posible acceder a bases de datos reales de empresas constructoras ni realizar entrevistas exhaustivas con profesionales del sector en la provincia de Misiones, se recurrió al uso de conjuntos de datos sintéticos (Data set 1 y 2) y reales (Data set 3).

Data set 1: fue generado mediante un script en Python se generó 100.000 registros de 40 columnas, relacionados con proyectos de construcción, algunas de las características son: nombre

del constructor, código del constructor, código del proyecto, nombre del proyecto, año, ubicación, etapa, dimensión, tipo de propiedad, material nombre, material descripción, precio del material. Este conjunto incluye información simulada sobre la ubicación del proyecto, valoraciones del constructor, la seguridad, sociedad y amenidad relacionados a la ubicación de la propiedad. Se utilizó para pruebas iniciales y simulaciones [17].

Las características y descripción estadística del conjunto se pueden apreciar en la Fig. 3.




Fig. 3. Características y descripción estadística del Data set 1.

Para identificar los datos relevantes, se procedió a listar las variables numéricas (medibles) y las variables categóricas (contextuales). Esto se aprecia en la Fig. 4.

```

numericas = data.select_dtypes(include=['int64', 'float64']).columns.tolist()
categoricas = data.select_dtypes(include=['object']).columns.tolist()

print("\n Variables numéricas (medibles):", len(numericas))
print(numericas)
print("\n Variables categóricas (contextuales):", len(categoricas))
print(categoricas)

• Variables numéricas (medibles): 15
['rateSqMeter', 'year', 'Flat available', 'totalOccupied_flat', 'totalBooked', 'customerPhone', 'interiorQualityRating', 'exteriorQualityRating', 'societyRating', 'securityRating', 'BuilderRating', 'materialPrice', 'materialQty', 'propertyArea', 'propertyPrice']

• Variables categóricas (contextuales): 25
['builder_name', 'BuilderCode', 'projectCode', 'propertyName', 'location', 'stage', 'dimension', 'propertyType', 'onTime', 'expectedDeliveryDate', 'actualDeliveryDate', 'customerCode', 'projectCode.1', 'propertyType.1', 'customerName', 'customerEmail', 'possessionDate', 'amenities', 'materialCode', 'materialName', 'materialDescription', 'date', 'unit', 'propertyCode', 'propertyAddress']

```

Fig. 4. Variables numéricas y variables categóricas del Data set 1.

Seguidamente, se procedió a obtener las respectivas distribuciones de las variables numéricas (Fig. 5) y la correlación entre las variables (Fig. 6).




Fig. 5. Distribución estadística de las variables numéricas.

Se implementó la librería FLAML de AutoML para evaluar cuál es el mejor modelo de predicción según el set de datos; el algoritmo recomendado fue `extra_tree` con una exactitud del 99% (Fig. 7).

Se entrenó el modelo `extra_tree` con set de entrenamiento, ya que se dividió el data set en dos conjuntos. Set de entrenamiento con el 80% de los datos y set de prueba con el 20% los datos (Fig. 8).




Fig. 6. Mapa de correlación entre variables.

```
[flaml.automl.logger: 10-18 22:43:06] {2724} INFO - retrain extra_tree for 20.7s
[flaml.automl.logger: 10-18 22:43:06] {2727} INFO - retrained model: ExtraTreesRegressor(max_leaf_nodes=7232, n_estimators=198, n_jobs=1,
random_state=12032022)
[flaml.automl.logger: 10-18 22:43:06] {2009} INFO - fit succeeded
[flaml.automl.logger: 10-18 22:43:06] {2010} INFO - Time taken to find the best model: 83.58075213432312
🏆 Mejor modelo encontrado: extra_tree
R² en test: 0.9999939741040934
```

Fig. 7. Mejor modelo encontrado por AutoML (extra_tree).

```
=== EVALUACIÓN DEL MODELO ===
R² Train: 1.000000
R² Test: 0.927205
MAE Train: 0.00
MAE Test: 335,599.67
RMSE Train: 0.00
RMSE Test: 422,627.73
Error % Train: 0.00%
Error % Test: 19.70%
```

Fig. 8. Evaluación del modelo mediante MAE, R2 y RMSE.

Se aplicó validación cruzada (Fig. 9), para evaluar el modelo en múltiples divisiones de datos logrando una evaluación más robusta y evitando el *overfitting*. Los resultados obtenidos fueron en promedio: 0.917701 esto explica el modelo con el 9177% de varianza en promedio; con una

variabilidad: ± 0.004138 muy baja siendo excelente para el modelo y la consistencia se refleja mediante el *folds* que están entre 0.914 - 0.920.

```
print("\n🔍 === VALIDACIÓN CRUZADA ===")
cv_scores = cross_val_score(extra_trees_model, X_train, y_train,
                             cv=5, scoring='r2', n_jobs=-1)

print(f"R² Validación Cruzada (5-fold): {cv_scores.mean():.6f} (+/- {cv_scores.std() * 2:.6f})")
print("Scores por fold:", [f"{score:.6f}" for score in cv_scores])

🔍 === VALIDACIÓN CRUZADA ===
R² Validación Cruzada (5-fold): 0.917701 (+/- 0.004138)
Scores por fold: ['0.917117', '0.920621', '0.919444', '0.916430', '0.914893']
```

Fig. 9. Validación cruzada.

Mediante el análisis residual (Fig. 10) se observó que en el gráfico de residuales vs. predicciones los puntos no siguen un patrón claro, sino que están distribuidos de manera aleatoria alrededor de la línea cero y existen algunos puntos más dispersos en los valores centrales de las predicciones (posible problema). El gráfico predicciones vs valores reales muestra que el modelo tiene buena predicción, debido a que los puntos se agrupan de manera aceptable alrededor de la línea roja, asegurando una buena correlación del modelo. Y por último el gráfico distribución residual permite interpretar que la distribución es normal, la mediana está cerca de cero, la forma es simétrica con una leve asimetría hacia la izquierda.




Fig. 10. Resultado análisis residual.

Los resultados obtenidos al evaluar el modelo con el set de test permiten describir que el R^2 Score fue de 0.9272, esto significa un excelente rendimiento, dado que el modelo logra explicar el 92.72% de la variabilidad en los datos. Los errores absoluto promedio (error cuadrático medio $RMSE = 422,627.73$ y error absoluto $MAE: 335,599.67$) muestran que las predicciones se desvían en promedio \$335,600 del valor real, en este punto se deberá considerar el rango típico de los valores para así evaluar si esto es bueno o malo.

El gráfico de la figura 11, muestra la Distribución Asimétrica Positiva Mediana (11.14%) < Promedio (19.70%) indicando la existencia de *outliers* que inflan el promedio. Además, se observa que el 25% de las predicciones tienen error $\leq 5.35\%$ (muy bueno) y el 75% de las predicciones tienen error $\leq 21.66\%$ (3 de cada 4 casos). La diferencia que se observa entre el Promedio = 19.70% y la Mediana = 11.14% significa que hay predicciones con errores muy altos que elevan el

promedio; por lo tanto, detectando y eliminando los *outliers*, el error típico sería alrededor del 11%.




Fig. 11. Evaluación del modelo con el set test (20000 ejemplos).

Por lo tanto, para el set de datos 1 el modelo `extra_tree` podrá estimar el costo de un proyecto con una capacidad explicativa excelente de $R^2 = 0.927$; el 50% de las predicciones con error $\leq 10\%$ y el 75% de casos con error $\leq 21.66\%$. Ofreciendo un buen rendimiento general para la mayoría de casos, siendo confiable para 73% de los casos aproximadamente y es problemático para el 27% de los casos restantes.

A continuación, se buscó el mejor modelo para estimar el tiempo utilizando el mismo Data set 1. Los pasos que se siguieron fueron: preprocesamiento de los datos para descartar características no relevantes para el modelo, selección del modelo, entrenamiento y prueba del modelo. Posterior a la limpieza de los datos el data set que se obtuvo se muestra en la Fig. 12.

En la Fig. 13a se muestra el modelo con mayor precisión para estimar el tiempo de finalización de un proyecto de construcción, nuevamente utilizamos la librería FLAML de AutoML. El modelo seleccionado fue `xgb_limitdepth` que es el modelo XGBoost con profundidad limitada, dando como salida R^2 en test = -0.00028, lo cual indica un grave error y es que el modelo no está aprendiendo. Como solución al problema detectado, se aplicó ingeniería de características (Fig. 13b), para definir un target más robusto, filtrar valores extremos, seleccionar características potencialmente relevantes y convertir algunas categorías, antes de aplicar nuevamente AutoML.

Los resultados preliminares (Fig. 14) evidencian un desempeño insuficiente, por lo que se propone realizar un análisis exploratorio más exhaustivo de los datos con el fin de identificar posibles *outliers* y mejorar la calidad del modelo.

```
Preprocesando datos...
Valores nulos por columna:
builder_name          0
BuilderCode           0
projectCode           0
projectName           0
rateSqMeter           0
year                  0
location              0
stage                 0
dimension             0
propertyType          0
Flat_available        0
totalOccupied_flat    0
totalBooked           0
onTime                0
expectedDeliveryDate  0
actualDeliveryDate    0
customerCode          0
projectCode.1         0
propertyType.1        0
customerName          0
customerEmail         0
customerPhone         0
possessionDate        0
interiorQualityRating 0
exteriorQualityRating 0
societyRating         0
securityRating        0
amenities             0
BuilderRating         0
materialCode          0
materialName          0
materialDescription    0
materialPrice         0
date                  0
materialQty           0
unit                  0
propertyCode          0
propertyAddress       0
propertyArea          0
propertyPrice         0
dtype: int64
Tamaño del dataset después de limpieza: (100000, 41)
```

Fig. 12a. Preprocesamiento de datos.

```

# Paso 5: Selección de características
# Columnas categóricas para codificar
categorical_features = [
    'builder_name', 'location', 'stage', 'dimension', 'propertyType',
    'onTime', 'amenities', 'unit'
]

# Columnas numéricas
numerical_features = [
    'rateSqMeter', 'year', 'Flat_available', 'totalOccupied_flat',
    'totalBooked', 'interiorQualityRating', 'exteriorQualityRating',
    'societyRating', 'securityRating', 'BuilderRating', 'materialPrice',
    'materialQty', 'propertyArea', 'propertyPrice'
]

# Codificar variables categóricas
label_encoders = {}
for col in categorical_features:
    if col in df.columns:
        le = LabelEncoder()
        df[col + '_encoded'] = le.fit_transform(df[col].astype(str))
        label_encoders[col] = le

# Crear conjunto final de características
feature_columns = [col + '_encoded' for col in categorical_features if col in df.columns] + numerical_features

# Eliminar columnas con valores nulos en las características
df_clean = df[feature_columns + ['days_until_delivery']].dropna()

print(f"Tamaño final del dataset: {df_clean.shape}")

Tamaño final del dataset: (100000, 23)

```

Fig. 12b. Selección de características.

```

monotone_constraints=None, multi_strategy=None, n_estimators=8,
n_jobs=-1, num_parallel_tree=None, ...)
[flaml.automl.logger: 10-19 12:11:13] {2009} INFO - fit succeeded
[flaml.automl.logger: 10-19 12:11:13] {2010} INFO - Time taken to find the best model: 50.822264432907104
🏆 Mejor modelo encontrado: xgb limitdepth
R² en test: -0.0002887007311913603

```

Fig. 13a. Selección de modelo para estimar el tiempo de finalización.

```

# Autómata con más tiempo y comparaciones mejoradas
automl = AutoML()

automl_settings = {
    "time_budget": 300, # 5 minutos
    "metric": 'r2',
    "task": 'regression',
    "estimator_list": ['lgbm', 'xgboost', 'rf'], # Forzar algoritmos potentes
    "seed": 42,
    "verbose": 2
}

print("🔍 Entrenando modelo mejorado...")
automl.fit(X_train=X_train, y_train=y_train, **automl_settings)

# Resultados
print("\n" + "*" * 50)
print("🏆 MEJOR MODELO:", automl.best_estimator)
y_pred = automl.predict(X_test)
r2 = r2_score(y_test, y_pred)
print("📊 R² en test:", r2)

# Diagnóstico
if r2 > 0.3:
    print("✅ ¡MEJORA SIGNIFICATIVA!")
elif r2 > 0:
    print("⚠️ Modelo mejorado pero necesita trabajo")
else:
    print("🔴 El problema persiste - necesita análisis más profundo")

🔴 19 características seleccionadas
📊 Tamaño del dataset: 90423 proyectos
🔍 Entrenando modelo mejorado...

=====
🏆 MEJOR MODELO: lgbm
📊 R² en test: -0.0005547782032857551
🔴 El problema persiste - necesita análisis más profundo

```

Fig. 13b. Selección del modelo posterior a la Ingeniería de características.




Fig. 14a. Análisis de variable objetivo.




Fig. 14b. Valores extremos y outliers.

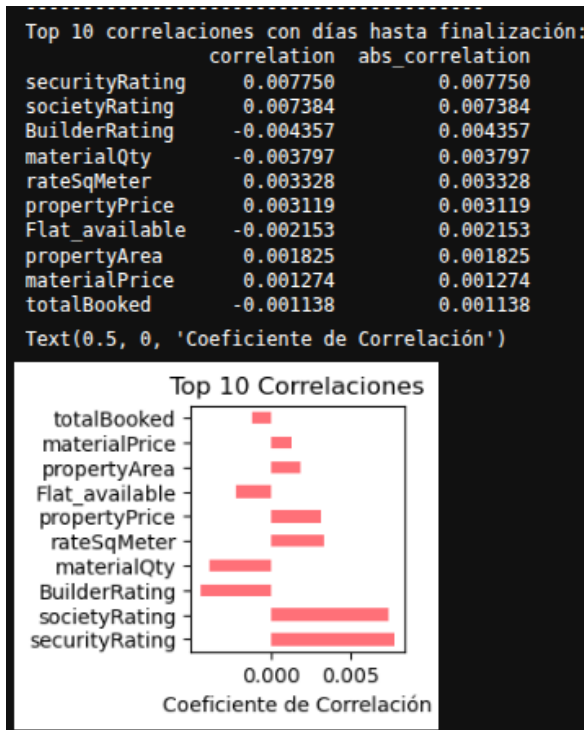


Fig. 14c. Análisis de correlaciones.




Fig. 14d. Análisis de información que comparten 2 variables.

Este análisis evidencia que el **Data set 1** contiene características que no presentan relación alguna con el tiempo de finalización del proyecto. Tanto las correlaciones como la información mutua resultan prácticamente nulas, lo que indica que las variables disponibles no aportan valor predictivo. Si bien la variable objetivo *days_until_completion* presenta valores entre 30 y 365 días, dichos tiempos no dependen de las características del proyecto.

Además, al tratarse de datos sintéticos o generados artificialmente, no reflejan relaciones reales propias del proceso constructivo y carecen de información crucial (como condiciones climáticas, permisos, mano de obra o capacidad del equipo). Ejemplos evidentes de esto son que un proyecto de 50 m² y otro de 500 m² registran exactamente el mismo tiempo de ejecución, o que un contratista con *rating* 1 finaliza en el mismo plazo que uno con *rating* 5.

Por lo tanto, se infiere que los tiempos de entrega se mantienen fijos o estandarizados, independientemente de las características consideradas. Las correlaciones observadas resultan muy débiles y las variables disponibles no aportan información predictiva relevante. En consecuencia, se decide trabajar con otro conjunto de datos, dado que este se considera de calidad insuficiente para abordar adecuadamente el problema planteado.

Data set 2: este set de datos se encuentra en [18], está compuesto por 300 ejemplos y 15 características. En la Fig. 15a y 15b se exhibe la descripción estadística de las características.

```
df.info()

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 300 entries, 0 to 299
Data columns (total 16 columns):
#   Column              Non-Null Count  Dtype
---  -
0   Project ID          300 non-null    object
1   Project Name        300 non-null    object
2   Project Type        300 non-null    object
3   Location            300 non-null    object
4   Start Date         300 non-null    object
5   End Date           300 non-null    object
6   Project Status     300 non-null    object
7   Priority            300 non-null    object
8   Task ID            300 non-null    object
9   Task Name          300 non-null    object
10  Task Status        300 non-null    object
11  Assigned To        300 non-null    object
12  Hours Spent        300 non-null    int64
13  Budget             300 non-null    int64
14  Actual Cost        300 non-null    int64
15  Progress           300 non-null    float64
dtypes: float64(1), int64(3), object(12)
memory usage: 37.6+ KB
```

Fig. 15a– Descripción de los ejemplos y características

```
df.describe()

      Hours Spent    Budget    Actual Cost    Progress
count  300.000000    300.000000    300.000000    300.000000
mean    19.210000   5624.266667   1728.070000    0.636067
std     11.505382   2706.584211   3012.743452    0.336683
min      0.000000   1026.000000     0.000000    0.000000
25%     10.000000   3312.000000     0.000000    0.352500
50%     18.500000   5751.500000     0.000000    0.680000
75%     29.000000   8287.750000   2667.000000    1.000000
max     40.000000   9998.000000  12398.000000    1.000000
```

Fig. 15b– Descripción estadística.

Para seleccionar el modelo más adecuado para predecir el tiempo de finalización de un proyecto de construcción, se identificaron las características categóricas más relevantes y se transformaron a variables numéricas mediante técnicas de codificación apropiadas.

Con la librería ProfileReport se realizó un análisis exploratorio (Fig. 16a y 16b), el cual ofrece como salida un informe interactivo (en HTML o dentro de Jupyter Notebook) que resume toda la información estadística y estructural del set de datos (como valores faltantes y correlación entre variables).

Project Name	
Text	
Distinct	100
Distinct (%)	33.3%
Missing	0
Missing (%)	0.0%
Memory size	2.5 KiB



Fig. 16a. Información de las características (ProfileReport).

Overview

Alerts5

Reproduction

Dataset statistics

Number of variables	16
Number of observations	300
Missing cells	203
Missing cells (%)	4.2%
Duplicate rows	0
Duplicate rows (%)	0.0%
Total size in memory	37.6 KiB
Average record size in memory	128.4 B

Variable types

Text	3
Categorical	7
DateTime	2
Numeric	4

Fig. 16b. Información estadística del data set (ProfileReport).

Seguidamente se realizó ingeniería de características para determinar las características más relevantes para el escenario planteado (Fig. 17).

```
# 5. Importancia de características
importancias = model.feature_importances_
feature_importance = pd.DataFrame({'Característica': features, 'Importancia': importancias})
feature_importance = feature_importance.sort_values('Importancia', ascending=False)

print("Características más relevantes para predecir días restantes:")
print(feature_importance)
```

	Característica	Importancia
0	duracion_planificada	0.911247
1	Progress	0.088753

evaluacion del modelo

Fig. 17. Ingeniería de características.

Se seleccionó el modelo Random Forest Regressor (siguiendo lo sugerido en la bibliografía). Para el entrenamiento se utilizó 80% de los ejemplos del data set, dejando el 20% de los ejemplos para las pruebas del modelo (Fig. 18). Los resultados obtenidos del entrenamiento del modelo se muestran en la Figura 19a y 19b.

```
# 3. Dividir datos en entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# 4. Entrenar modelo
model = RandomForestRegressor(random_state=42)
model.fit(X_train, y_train)
```

RandomForestRegressor

RandomForestRegressor(random_state=42)

Fig. 18. Entrenamiento del modelo

Los resultados obtenidos del entrenamiento del modelo se muestran en la Figura 19a y 19b.

```
# 5. Predecir y evaluar
y_pred = model.predict(X_test)

# Métricas de evaluación
mae = mean_absolute_error(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
rmse = np.sqrt(mse)
r2 = r2_score(y_test, y_pred)

print("\n📊 Métricas de Evaluación:")
print(f"- MAE (Error Absoluto Medio): {mae:.2f} días")
print(f"- MSE (Error Cuadrático Medio): {mse:.2f}")
print(f"- RMSE (Raíz del Error Cuadrático Medio): {rmse:.2f} días")
print(f"- R² (Coeficiente de Determinación): {r2:.2f}")

📊 Métricas de Evaluación:
- MAE (Error Absoluto Medio): 60.32 días
- MSE (Error Cuadrático Medio): 5286.07
- RMSE (Raíz del Error Cuadrático Medio): 72.71 días
- R² (Coeficiente de Determinación): 0.77
```

Fig. 19a. Evaluación y predicción del modelo.




Fig. 19b. Correlación del modelo con datos de entrenamiento.

Asimismo, este data set se utilizó para entrenar y evaluar el modelo XGBoost, los resultados no mejoraron, en la Figura 20 se muestran las métricas obtenidas.

```
# 6. Predecir y evaluar
y_pred = best_xgb.predict(X_test_scaled)

# Métricas de evaluación
mae = mean_absolute_error(y_test, y_pred)
mse = mean_squared_error(y_test, y_pred)
rmse = np.sqrt(mse)
r2 = r2_score(y_test, y_pred)

print("\n📊 Métricas de Evaluación (XGBoost):")
print(f"- MAE (Error Absoluto Medio): {mae:.2f} días")
print(f"- MSE (Error Cuadrático Medio): {mse:.2f}")
print(f"- RMSE (Raíz del Error Cuadrático Medio): {rmse:.2f} días")
print(f"- R² (Coeficiente de Determinación): {r2:.2f}")

📊 Métricas de Evaluación (XGBoost):
- MAE (Error Absoluto Medio): 60.10 días
- MSE (Error Cuadrático Medio): 5289.55
- RMSE (Raíz del Error Cuadrático Medio): 72.73 días
- R² (Coeficiente de Determinación): 0.77
```

Fig. 20. Entrenamiento y prueba del modelo XGBoost.

En cuanto a la predicción del costo se definió como target a la característica *Actual_Cost* y se seleccionó el modelo XGBRegressor. Las métricas obtenidas se pueden apreciar en la Fig. 21.

```
# =====
# 5. Evaluar
# =====
y_pred = model.predict(X_test)
print(f"MAE: {mean_absolute_error(y_test, y_pred):.2f}")
print(f"RMSE: {mean_squared_error(y_test, y_pred):.2f}")
print(f"R²: {r2_score(y_test, y_pred):.2f}")

MAE: 314.01
RMSE: 965121.70
R²: 0.89
```

Fig. 21. Métricas del modelo XGBRegressor.

Con el objetivo de mejorar el error cuadrático se decidió determinar las características más relevantes, para luego entrenar y probar el mismo modelo (Fig. 22a y 22b).




Fig. 22a. Características relevantes para estimar el costo.

Seguidamente, se probó y evaluó el modelo utilizando únicamente las características relevantes, logrando una mejora del 1 % respecto de las métricas obtenidas previamente (Fig. 23).

```
# =====
# 7. Imprimir ranking
# =====
feature_ranking = pd.DataFrame({
    "Feature": feature_names[indices],
    "Importance": importances[indices]
})
print(feature_ranking.head(15))
```

	Feature	Importance
0	Progress	0.830811
1	Budget	0.056030
2	End Date 27/07/2025	0.040093
3	End Date 15/06/2024	0.020782
4	Project ID_P075	0.014862
5	Project ID_P073	0.007075
6	Project Type_Other	0.005103
7	Hours Spent	0.004854
8	Location_Florida	0.004306
9	End Date 24/04/2024	0.003837
10	Project ID_P067	0.003218
11	Project ID_P027	0.001864
12	Project ID_P010	0.001725
13	Task Name_Task 001 of Building a Park Project 075	0.001702
14	Project ID_P021	0.001093

Fig. 22b. Ranking de características.

```
X_scaled = scaler.fit_transform(X_encoded)

# =====
# 3. Entrenamiento inicial para obtener importancia
# =====
model_init = xgb.XGBRegressor(
    n_estimators=200,
    learning_rate=0.05,
    max_depth=6,
    random_state=42
)
model_init.fit(X_scaled, y)

# Obtener importancia
importances = model_init.feature_importances_
feature_names = X_encoded.columns
importance_df = pd.DataFrame({
    "Feature": feature_names,
    "Importance": importances
}).sort_values(by="Importance", ascending=False)

# Seleccionar características que sumen hasta el 95% de la importancia
importance_df["Cumulative"] = importance_df["Importance"].cumsum()
selected_features = importance_df[importance_df["Cumulative"] <= 0.95]["Feature"].tolist()

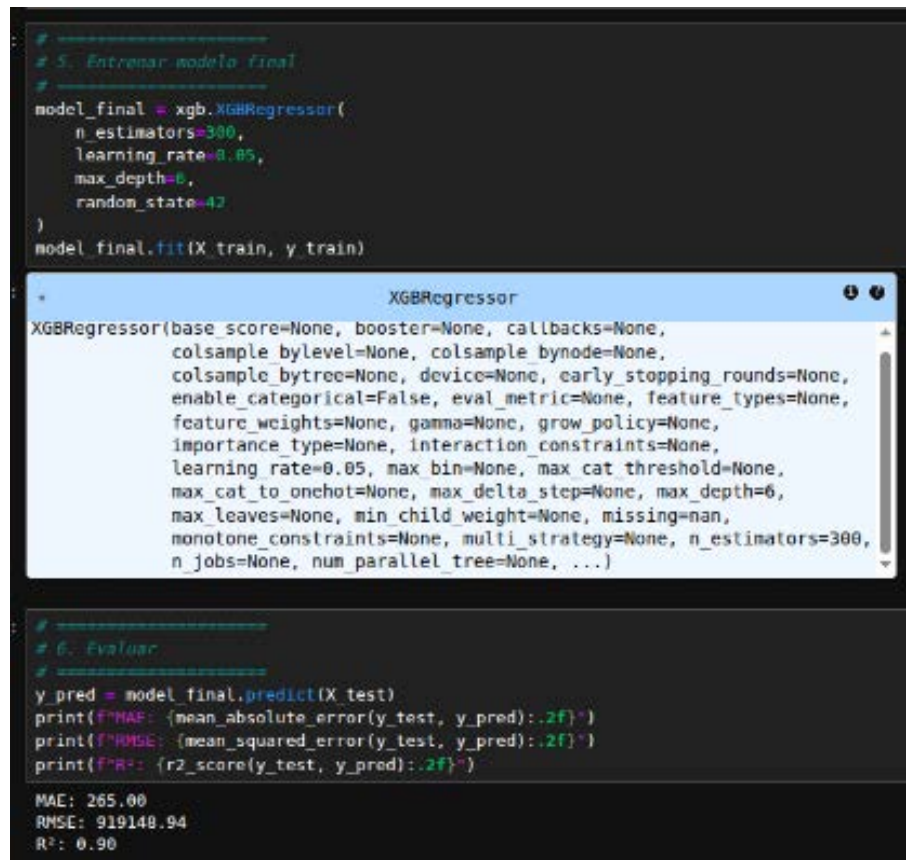
print(f"Se seleccionaron {len(selected_features)} características más relevantes.")

Se seleccionaron 4 características más relevantes.

# =====
# 4. Filtrar dataset con las mejores features
# =====
X_selected = X_encoded[selected_features]
X_train, X_test, y_train, y_test = train_test_split(
    X_selected, y, test_size=0.2, random_state=42
)
```

Fig. 23. Filtrado de las características relevantes para estimar el costo.

Los resultados del entrenamiento del modelo XGBRegressor utilizando las cuatro características más relevantes se muestran en la Figura 24.



```

# 5. Entrenar modelo final
#
model_final = xgb.XGBRegressor(
    n_estimators=300,
    learning_rate=0.05,
    max_depth=6,
    random_state=42
)
model_final.fit(X_train, y_train)

# 6. Evaluar
y_pred = model_final.predict(X_test)
print(f'MAE: {mean_absolute_error(y_test, y_pred):.2f}')
print(f'RMSE: {mean_squared_error(y_test, y_pred):.2f}')
print(f'R²: {r2_score(y_test, y_pred):.2f}')

MAE: 265.00
RMSE: 919149.94
R²: 0.90

```

Fig. 24. Métricas de XGBRegressor.

Data set 3: compuesto por 378 ejemplos con 109 características relacionados a proyectos de construcción [19].

Para evaluar la viabilidad de utilizar este conjunto de datos en el proyecto desarrollado, se recurrió a una consulta mediante NotebookLM, a fin de obtener un análisis inicial sobre su pertinencia y calidad [20]. El objetivo fue evaluar la relevancia del data set para estimar tiempo y costo en la finalización de proyectos de construcción. La salida proporcionada fue un documento con una gran cantidad de datos relacionados con proyectos de construcción residencial, organizados según el calendario persa, con columnas para el año/trimestre de inicio del proyecto y el año/trimestre de finalización del proyecto. Una sección significativa de la información se centra en variables físicas y financieras del proyecto (V-1 a V-10), incluyendo medidas de área como metros cuadrados (m^2) y valores monetarios en la moneda iraní (Rial). Además, el texto enumera extensas variables e índices económicos (V-11 a V-29), como el índice de precios al por mayor (WPI), la liquidez acumulada, y varios índices de precios al consumidor (IPC), presentados con hasta cinco retrasos de tiempo para el análisis. Finalmente, el pie de página aclara que algunas variables se han calibrado entre 0 y 1 y proporciona definiciones para los identificadores de las variables.

La preparación de los datos para el modelado consistió en cargar el conjunto de datos omitiendo las filas de encabezado incorrectas, para luego identificar la estructura real de la información. A partir de ello, se construyó un nuevo *Data Frame* con la organización adecuada, se determinaron las columnas clave y se analizaron patrones en su nomenclatura. Finalmente, se asignaron nombres más claros y consistentes, atendiendo a la estructura del conjunto de datos: columnas 0–3

correspondientes a fechas del proyecto; columnas 4–11 asociadas a variables físicas y financieras (V-1 a V-8); y las dos últimas columnas correspondientes a las variables objetivo (V-9 y V-10).

La variable objetivo (target) seleccionada para la estimación del tiempo de ejecución del proyecto corresponde a la característica V-7 del conjunto de datos, denominada **“Duration of Construction”**, la cual presenta un tipo de dato numérico. Por otro lado, para la predicción del gasto total del proyecto, se definió como target la característica V-10, asociada a **“Actual Construction Costs (output)”**, es decir, el costo real incurrido durante la construcción.

La selección de ambas variables se sustenta en su relación directa con los objetivos planteados en esta etapa del estudio (Figs. 25a, 25b, 25c y 25d).

Datos cargados correctamente. Dimensiones del DataFrame de datos: (377, 109)

Primeras 5 filas del DataFrame de datos:

	START YEAR	START QUARTER	COMPLETION YEAR	COMPLETION QUARTER	V-1	V-2	\
0	81	1.0	85.0	1.0	1.0	3150.0	
1	84	1.0	89.0	4.0	1.0	7600.0	
2	78	1.0	81.0	4.0	1.0	4800.0	
3	72	2.0	73.0	2.0	1.0	685.0	
4	87	1.0	90.0	2.0	1.0	3000.0	

	V-3	V-4	V-5	V-6	V-7	V-8	V-11	V-12	V-13	V-14	\
0	920.0	598.5	190.0	1010.84	16.0	1200.0	6713.09	56.2	61.52	6.11	
1	1140.0	3040.0	400.0	963.81	23.0	2900.0	3152.09	106.0	103.03	3.15	
2	840.0	400.0	100.0	689.84	15.0	630.0	1627.00	41.0	41.25	1.74	
3	202.0	13.7	20.0	459.54	4.0	140.0	2580.93	12.1	10.03	1.24	
4	800.0	1230.0	410.0	631.91	13.0	5000.0	6790.00	203.8	162.84	6.46	

	V-15	V-16	V-17	V-18	V-19	V-20	V-21	V-22	V-23	\
0										
1										
2										
3										
4										

Fig. 25a. Data Frame.

```
--- Nombres de TODAS las columnas en df_data ---
['START YEAR', 'START QUARTER', 'COMPLETION YEAR', 'COMPLETION QUARTER', 'V-1', 'V-2', 'V-3', 'V-4', 'V-5', 'V-6', 'V-7', 'V-8', 'V-11', 'V-12', 'V-13', 'V-14', 'V-15', 'V-16', 'V-17', 'V-18', 'V-19', 'V-20', 'V-21', 'V-22', 'V-23', 'V-24', 'V-25', 'V-26', 'V-27', 'V-28', 'V-29', 'V-11.1', 'V-12.1', 'V-13.1', 'V-14.1', 'V-15.1', 'V-16.1', 'V-17.1', 'V-18.1', 'V-19.1', 'V-20.1', 'V-21.1', 'V-22.1', 'V-23.1', 'V-24.1', 'V-25.1', 'V-26.1', 'V-27.1', 'V-28.1', 'V-29.1', 'V-11.2', 'V-12.2', 'V-13.2', 'V-14.2', 'V-15.2', 'V-16.2', 'V-17.2', 'V-18.2', 'V-19.2', 'V-20.2', 'V-21.2', 'V-22.2', 'V-23.2', 'V-24.2', 'V-25.2', 'V-26.2', 'V-27.2', 'V-28.2', 'V-29.2', 'V-11.3', 'V-12.3', 'V-13.3', 'V-14.3', 'V-15.3', 'V-16.3', 'V-17.3', 'V-18.3', 'V-19.3', 'V-20.3', 'V-21.3', 'V-22.3', 'V-23.3', 'V-24.3', 'V-25.3', 'V-26.3', 'V-27.3', 'V-28.3', 'V-29.3', 'V-11.4', 'V-12.4', 'V-13.4', 'V-14.4', 'V-15.4', 'V-16.4', 'V-17.4', 'V-18.4', 'V-19.4', 'V-20.4', 'V-21.4', 'V-22.4', 'V-23.4', 'V-24.4', 'V-25.4', 'V-26.4', 'V-27.4', 'V-28.4', 'V-29.4', 'V-9', 'V-10']
```

Fig. 25b. Encabezado de las características.




Fig. 25c. Distribución estadística target V-10.




Fig. 25d. Distribución estadística target V-7.

Posteriormente, se llevó a cabo el preprocesamiento del conjunto de datos, el cual incluyó la identificación y clasificación de las características en categóricas y numéricas, la detección de valores nulos o faltantes, y el análisis de correlaciones entre variables para evaluar relaciones significativas. Las variables categóricas fueron transformadas en características numéricas mediante la técnica *One-Hot Encoding*, empleando la librería Pandas, que genera una nueva columna para cada categoría presente en la variable original. Asimismo, se realizó la estandarización de las características numéricas, procedimiento fundamental para garantizar un desempeño adecuado en numerosos algoritmos de ML al homogenizar las escalas de los datos. Este proceso de preparación se resume en las Figs. 26a, 26b, 26c y 26d.

```
Correlación FUERTE ( $\geq 0.5$ ) con las variables target:

--- Correlación con V-7 ---
No hay variables con correlación absoluta  $\geq 0.5$ 

--- Correlación con V-10 ---
V-5      0.963322
V-9      0.796041
V-8      0.789944
V-13.3   0.780323
V-25.3   0.780152
...
V-24.2   0.606195
V-24     0.604706
V-4      0.602107
V-19.3   0.566040
V-20     -0.521631
Name: V-10, Length: 76, dtype: float64
```

Fig. 26a. Correlaciones fuertes entre características.

```
--- INICIANDO LIMPIEZA ADICIONAL DE VARIABLES TARGET ---
Filas originales: 377
Filas eliminadas (donde TARGET_TIME o TARGET_COST era NaN): 5
Filas finales en df data: 372
NaN restantes en V-7: 0
NaN restantes en V-10: 0
```

Fig. 26b. Eliminación de valores nulos.

```

Dimensiones del DataFrame después de la codificación: (377, 125)
Primeras filas del DataFrame procesado:
  START QUARTER  COMPLETION YEAR  COMPLETION QUARTER  V-1  V-2  \
0      -1.105476      0.485340      -1.426761 -1.336466  0.798083
1      -1.105476      1.439569      1.262683 -1.336466  3.285618
2      -1.105476      -0.468888      1.262683 -1.336466  1.720428
3      -0.175198      -2.377345      -0.530279 -1.336466 -0.579843
4      -1.105476      1.678126      -0.530279 -1.336466  0.714234

  V-3  V-4  V-5  V-6  V-7  V-8  V-11  V-12  \
0  1.018881  0.487635  0.243327  1.673835  16.0  0.116994  1.422980 -0.608195
1  1.471207  4.852495  2.122757  1.501522  23.0  1.836944 -0.596062  0.189512
2  0.854399  0.275783 -0.562144  0.497720  15.0 -0.459695 -1.460718 -0.851672
3 -0.457346 -0.557857 -1.278117 -0.346078  4.0 -0.955446 -0.919852 -1.314598
4  0.772158  1.616617  2.212253  0.285470  13.0  3.961588  1.466638  1.756093

```

Fig. 26c. Estandarización de características numéricas.

```

  START YEAR_80  START YEAR_81  START YEAR_82  START YEAR_83  START YEAR_84  \
0      False      True      False      False      False
1      False      False      False      False      True
2      False      False      False      False      False
3      False      False      False      False      False
4      False      False      False      False      False

  START YEAR_85  START YEAR_86  START YEAR_87  START YEAR_88  \
0      False      False      False      False
1      False      False      False      False
2      False      False      False      False
3      False      False      False      False
4      False      False      True      False

  START YEAR_89  \
0      False
1      False
2      False
3      False
4      False

```

Fig. 26d. Transformación de características categóricas.

Finalizado el proceso de preprocesamiento, se empleó la librería FLAML con el objetivo de identificar los algoritmos de ML más adecuados para la predicción del tiempo de construcción y del costo del proyecto en este conjunto de datos.

Como resultado de esta optimización automática de modelos, FLAML determinó que el algoritmo *Stochastic Gradient Descent* (SGD) es el más apropiado para la estimación del tiempo de construcción, obteniendo el mejor desempeño en las métricas evaluadas (Fig. 27).

```

[flaml.automl.logger: 10-25 19:45:38] {2724} INFO - retrain sgd for 0.0s
[flaml.automl.logger: 10-25 19:45:38] {2727} INFO - retrained model: SGDRegressor(alpha=0.00010223665070559743, learning_rate='optimal',
    loss='epsilon insensitive', penalty='l1', tol=0.0001)
[flaml.automl.logger: 10-25 19:45:38] {2009} INFO - fit succeeded
[flaml.automl.logger: 10-25 19:45:38] {2010} INFO - Time taken to find the best model: 136.19817352294922

Mejor modelo para Tiempo: sgd
Métrica de entrenamiento (RMSE): -1.0189
RMSE en el conjunto de prueba para Tiempo: 1.1452

```

Fig. 27. Salida de FLAML para estimar el tiempo.

De manera análoga, para identificar el modelo más adecuado en la predicción del costo total del proyecto, se aplicó nuevamente FLAML, el cual recomendó el algoritmo con el mejor desempeño para esta tarea (Fig. 28).

```

monotone_constraints=None, multi_strategy=None, n_estimators=172,
n_jobs=-1, num_parallel_tree=None, ...)
[flaml.automl.logger: 10-25 20:33:34] {2009} INFO - fit succeeded
[flaml.automl.logger: 10-25 20:33:34] {2010} INFO - Time taken to find the best model: 286.52819657325745

Mejor modelo para Costo: xgboost
Métrica de entrenamiento (RMSE): -38.1013
RMSE en el conjunto de prueba para Costo: 36.1734

```

Fig. 28. Salida de FLAML para estimar el costo.

A continuación, se muestra el resultado que se obtuvo durante el entrenamiento y prueba para estimar el tiempo con el modelo SGD (Fig. 29).

Como se observa en las Figs. 29a y 29b, la evaluación del modelo SGD evidencia un rendimiento moderado: el MAE = 1.2879 resulta considerablemente menor que el RMSE = 1.7848, lo que indica la presencia de algunos errores elevados y, por ende, posibles *outliers*. Por su parte, el coeficiente de determinación $R^2 = 0.3892$ (aprox. 38.92 %) sugiere que el modelo explica una fracción limitada de la variabilidad en la duración de los proyectos, dejando alrededor del 61 % de la variación sin capturar.

Frente a este desempeño, se decidió explorar modelos no lineales de mayor complejidad, tales como **XGBoost** y **LightGBM**, los cuales fueron evaluados también con FLAML, con el objetivo de incrementar el valor de R^2 por encima del 0.60 o incluso 0.70 (Fig. 30a y 30b).

Entre los tres modelos evaluados (SGD, LGBM y XGBoost), la opción más adecuada para predecir el tiempo de finalización es SGD. Este modelo obtiene el mejor desempeño en el error RMSE (1.7848) —indicador sensible a la presencia de *outliers*— y se posiciona segundo en MAE (1.2879). Además, presenta el mayor poder explicativo, con un $R^2 = 0.3892$, lo que lo convierte en la alternativa más sólida dentro del conjunto de algoritmos analizados (Fig. 31).

Para la estimación del costo del proyecto, se empleó el algoritmo XGBoost, recomendado por el proceso de selección automática de modelos (Fig. 32).

Como se observa en las métricas de la Fig. 32, el modelo alcanzó un $R^2 = 0.9249$ (92.49 %), lo que constituye un desempeño sobresaliente. Este nivel de ajuste indica que XGBoost es capaz de explicar prácticamente toda la variabilidad de los costos de construcción a partir de las características del proyecto y de las variables económicas consideradas. En consecuencia, se trata de un modelo con alta capacidad predictiva y robustez en el análisis.

```
=====
ENTRENANDO MODELO SGD PARA ESTIMACIÓN DE TIEMPO (V7)
=====
Modelo SGD entrenado exitosamente.

--- METRICAS DE EVALUACIÓN (CONJUNTO DE PRUEBA) ---
RMSE (Error Cuadrático Medio Raíz): 1.7848
MAE (Error Absoluto Medio): 1.2879
R2 (Coeficiente de Determinación): 0.3892
-----
```

Fig. 29a. Métricas para SGD.




Fig. 29b– Predicción de SGD.

```
=====
ENTRENANDO MODELO LGBM PARA ESTIMACIÓN DE TIEMPO (V7)
=====
Modelo LightGBM entrenado exitosamente.

--- METRICAS DE EVALUACIÓN (CONJUNTO DE PRUEBA) ---
RMSE (Error Cuadrático Medio Raíz): 1.9635
MAE (Error Absoluto Medio): 1.3354
R2 (Coeficiente de Determinación): 0.2607
=====
```

Fig. 30a. Métricas del modelo LGBM.

```
=====
ENTRENANDO MODELO XGBOOST PARA ESTIMACIÓN DE TIEMPO (V7)
=====
Modelo XGBoost entrenado exitosamente.

--- METRICAS DE EVALUACIÓN (CONJUNTO DE PRUEBA) ---
RMSE (Error Cuadrático Medio Raíz): 1.8712
MAE (Error Absoluto Medio): 1.2577
R2 (Coeficiente de Determinación): 0.3286
=====
```

Fig. 30b. Métricas del modelo XGBoost.




Fig. 31. Comparación de modelos para predecir el tiempo.

```
=====
ENTRENANDO MODELO XGBOOST PARA ESTIMACIÓN DE COSTO (V-10)
=====
Modelo XGBoost de Costo entrenado exitosamente.

--- METRICAS DE EVALUACIÓN (CONJUNTO DE PRUEBA) ---
RMSE (Error Cuadrático Medio Raíz): 45.9245
MAE (Error Absoluto Medio): 25.6409
R2 (Coeficiente de Determinación): 0.9249
=====
```

Fig. 32. Métricas de XGBoost.

3.2. Observaciones de los modelos aplicados

En función del alcance definido para este estudio, la evaluación de los modelos se realizó mediante validación cruzada estándar y partición entrenamiento/prueba, según el conjunto de datos analizado. No se aplicaron esquemas de validación cruzada anidada, análisis formal de incertidumbre ni técnicas de explicabilidad de modelos, los cuales se consideran extensiones metodológicas relevantes para etapas futuras del trabajo.

Se entrenaron y evaluaron múltiples modelos de regresión utilizando bibliotecas como scikit-learn, pandas y matplotlib. La validación del rendimiento se realizó sobre el conjunto de prueba, empleando métricas estándar como el coeficiente de determinación (R^2).

Los resultados iniciales obtenidos para la predicción de los días de retraso reflejaron un desempeño deficiente ($R^2 = -0.07$), lo que evidencia que el modelo no lograba capturar adecuadamente la variabilidad del fenómeno. Esta situación motivó la revisión y ajuste de las variables sintéticas para incrementar su representatividad.

Estos hallazgos subrayan la importancia de formular hipótesis sólidas y validadas antes de intervenir los datos, con el fin de prevenir el sesgo de adaptar los datos a la hipótesis, cuando en realidad debe ocurrir lo contrario.

3.3. Implementación y monitoreo

Si bien este trabajo no contempla una implementación en producción, en etapas futuras se prevé la integración de los modelos desarrollados en aplicaciones web o sistemas de gestión de proyectos, con el fin de posibilitar su uso operativo por parte de los actores del sector. Asimismo, se plantea la comparación del desempeño de dichos modelos utilizando datos reales, contrastándolos con métodos tradicionales como CPM, PERT y la simulación Montecarlo. Finalmente, se destaca la importancia del monitoreo, mantenimiento y actualización periódica de los modelos predictivos, dado que los patrones de los datos pueden evolucionar con el tiempo y afectar la estabilidad y precisión de las predicciones.

4. Conclusiones

El estudio demuestra que los modelos de IA, en particular los basados en aprendizaje automático como *Random Forest*, *Extra Trees* y *XGBoost*, ofrecen un desempeño predictivo altamente confiable para la estimación de costos de construcción, alcanzando niveles de precisión superiores al 90 %. Estos resultados confirman el potencial de la IA como herramienta estratégica de apoyo a la gestión y planificación de obras en contextos caracterizados por alta incertidumbre.

No obstante, la precisión en la predicción del tiempo de finalización depende en gran medida de la disponibilidad y calidad de los datos de entrada. La limitada cantidad de conjuntos de datos reales en la provincia de Misiones constituyó la principal restricción del estudio, lo que pone de manifiesto la necesidad urgente de desarrollar una base de datos estructurada, abierta y actualizable sobre proyectos de construcción a nivel provincial.

En este marco, se recomienda avanzar hacia la integración de fuentes heterogéneas de información (técnicas, económicas y geoespaciales) en una plataforma interoperable, idealmente dentro del ecosistema IDE Misiones, a fin de facilitar la generación de modelos predictivos robustos y escalables. Asimismo, se proyecta la futura incorporación de técnicas de aprendizaje profundo y modelos híbridos IA-BIM, que permitan abordar dimensiones adicionales como sostenibilidad, eficiencia energética y gestión de riesgos. Además, se prevé la incorporación de esquemas de validación cruzada anidada, análisis de incertidumbre e interpretabilidad de los modelos predictivos, con el objetivo de fortalecer la robustez, transparencia y aplicabilidad operativa de los resultados obtenidos.

En síntesis, este trabajo constituye un aporte metodológico relevante para la digitalización del sector de la construcción en entornos regionales, evidenciando que la IA puede transformar la forma en que se planifican, ejecutan y controlan los proyectos, al ofrecer estimaciones más precisas, ágiles y respaldadas por datos.

Referencias

- [1] Djatnika, Suntana Sukma, Witjaksana, Budi, Oetomo, Wateno, y Bambang, W., «Risk Analysis on the Construction Project of the Basement Building under Jalan Pemuda-Yos Sudarso, Surabaya», *J. Phys. Conf. Ser.*, vol. 1364, 2019, doi: 10.1088/1742-6596/1364/1/012073.
- [2] Ullah, K, Abdullah, A. H., Nagapan, S., Suhoo, S., y Khan, M. S., «Theoretical framework of the causes of construction time and cost overruns» *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 271, 2017, doi: 10.1088/1757-899X/271/1/012032.

- [3] Anastasia Stepanets, «Método de la ruta crítica en la gestión de proyectos», <https://blog.ganttpro.com/>. [En línea]. Disponible en: <https://blog.ganttpro.com/es/metodo-de-la-ruta-critica-en-la-administracion-de-proyectos/>. Accedido el: 28/10/2025.
- [4] Team Asana, «El diagrama de PERT: qué es y cómo crearlo (incluye ejemplos)». [En línea]. Disponible en: <https://asana.com/>. Accedido el: 28/10/2025.
- [5] Sonia Coma, «Método de simulación Montecarlo: Qué es y cómo adoptarlo en tu empresa» [En línea]. Disponible en: <https://asana.com/>. Accedido el: 28/10/2025.
- [6] Setiawan, A, Fadjar, A., y Labombang, M., «Scheduling the Construction of Low-Income Community Houses in Palu City Using the Probabilistic Duration Method», *IOP Conf. Ser. Earth Environ. Sci.*, vol. 1355, 2024, doi: 10.1088/1755-1315/1355/1/012013.
- [7] Mirindi, Derrick, Mirindi, Frederic, Bezabih, Tajebe, Sinkhonde, David, y Kiarie, Winfred, «Review: The Role of Artificial Intelligence in Building Information Modeling», - *SIMIS-CPR*, 2025, doi: 10.1145/3716489.3728433.
- [8] Nihad Hassan, «AI vs. machine learning vs. deep learning: Key differences», <https://www.techtarget.com/>. [En línea]. Disponible en: https://www.techtarget.com/searchenterpriseai/tip/AI-vs-machine-learning-vs-deep-learning-Key-differences/?utm_source=chatgpt.com. Accedido el: 28/10/2025.
- [9] I. H. Sarker, «Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions», *SN Comput. Sci.*, vol. 2, 2021, doi: 10.1007/s42979-021-00815-1.
- [10] Demiss, Belachew A. y Elsaigh, Walied A., «Application of novel hybrid deep learning architectures combining Convolutional Neural Networks (CNN) and Recurrent Neural Networks (RNN): construction duration estimates prediction considering preconstruction uncertainties», *Eng. Res. Express* vol. 6, 2024, doi: 10.1088/2631-8695/ad6ca7.
- [11] Soreti M Liben, Demiss A Belachew, y Walied A Elsaigh, «Comparing advanced and traditional machine learning algorithms for construction duration prediction: a case study of Addis Ababa's public sector» *Eng. Res. Express*, vol. 6, 2024, doi: 10.1088/2631-8695/ad979f.
- [12] Mohammad Savargiv, Behrooz Masoumi, y Mohammad Reza Keyvanpour, «A New Random Forest Algorithm Based on Learning», *Comput. Intell. Neurosci.*, 2021, doi: 10.1155/2021/5572781.
- [13] Zi-Yi Yang, Zhao -Feng Ye, Chang-Yu Hsieh, y Yi-Jia Xiao, «SPLDE XTRA T REES : R OBUST MACHINE LEARNING APPROACH FOR PREDICTING KINASE INHIBITOR RESISTANCE», *arXiv preprint*, 2021.
- [14] Cynthia Lokker, Wael Abdelkader, y Elham Bagheri, «Boosting efficiency in a clinical literature surveillance system with LightGBM», *PLOS Digit. Health*, 2024, doi: /10.1371/journal.pdig.0000299.
- [15] Chi Wang, Qingyun Wu, Markus Weimer, y Erkang Zhu, «FLAML: A F AST AND L IGH TWEIGHT AUTO ML LIBRARY», *Proc. 4 Th MLSys Conf.*, 2021.
- [16] Arunn Thevapalan, «The Machine Learning Workflow Explained (and How You Can Practice It Now)». [En línea]. Disponible en: <https://towardsdatascience.com/>. Accedido el: 28/10/2025.
- [17] Deepakcode07, «Construction-Project-Data-Generator». <https://github.com/>. [En línea]. Disponible en: https://github.com/Deepakcode07/Construction-Project-Data-Generator?utm_source=chatgpt.com. Accedido el: 28/10/2025.
- [18] «JohnVans123/ProjectManagement». [En línea]. Disponible en: https://huggingface.co/datasets/JohnVans123/ProjectManagement?utm_source=chatgpt.com. Accedido el: 28/10/2025.
- [19] Mohammad Rafiei, «Residential Building». [En línea]. Disponible en: https://archive.ics.uci.edu/dataset/437/residential%2Bbuilding%2Bdata%2Bset?utm_source=chatgpt.com. Accedido el: 28/10/2025.
- [20] Google, *NotebookLM*. [En línea]. Disponible en: <https://notebooklm.google/>. Accedido el: 28/10/2025.

Impacto Hidrológico de la Infraestructura Vial Rural Sobre la Dinámica de la Cuenca Polvorín-Palometa

Lucas E. Álvarez^{1,*} , Guillermo J. Mendez^{1,2,3} , Alejandro R. Ruberto^{2,3} , Jorge V. Pilar^{1,2,3} ,
Marcelo J. M. Gómez^{2,3} , Carlos A. Depettris² 

¹ Administración Provincial del Agua (APA). Departamento de Proyectos y Evaluación. Chaco, Argentina

² Universidad Nacional del Nordeste. Facultad de Ingeniería. Chaco, Argentina

³ Universidad Nacional de Misiones. Facultad de Ingeniería. Misiones, Argentina.

e-mails: emmanuel72018@hotmail.com, guillermo.mendez@ing.unne.edu.ar,

jvpilar@gmail.com, aleruberto44@yahoo.com.ar, mgichaco@yahoo.com.ar, carlosdepettris@gmail.com

Resumen

El presente trabajo analiza la problemática hidráulica detectada en el camino Guayaibí, ubicado entre las ciudades de Machagai y Presidencia de la Plaza, en el Chaco. Tras las precipitaciones extraordinarias registradas el 6 de mayo de 2025, se produjeron anegamientos que afectaron la continuidad del escurrimiento y generaron inundaciones en sectores urbanos de Machagai. Mediante la aplicación de una metodología basada en información satelital, estimación de precipitaciones de diseño y modelación hidrológica con HEC-HMS, se evaluaron escenarios sin y con camino. Los resultados muestran que, aun con una correcta adecuación hidráulica, la presencia del terraplén vial provoca reducción de los caudales de salida y un incremento en el tiempo de permanencia de las aguas en áreas anegables, aunque sin variaciones significativas en los niveles de altura debido a la escasa pendiente del terreno. Asimismo, se evidencia que el almacenamiento natural en cañadas, esteros y zonas bajas atenúa los caudales de salida, lo que resalta la necesidad de preservar estos ambientes como parte fundamental de la gestión hídrica en cuencas de llanura.

Palabras clave – Hidrología de llanura, Infraestructura vial, Modelación Hidrológica, HEC-HMS

Abstract

This study analyzes the hydraulic problems observed along the Guayaibí road, located between the towns of Machagai and Presidencia de la Plaza, in Chaco Province. After the extraordinary rainfall recorded on May 6, 2025, flooding occurred that disrupted natural drainage and caused inundations in urban areas of Machagai. By applying a methodology based on satellite data, design rainfall estimation, and hydrological modeling with HEC-HMS, scenarios without and with the road were evaluated. The results show that, even with proper hydraulic adequacy, the presence of the road embankment produces a reduction in outflow discharges and an increase in the residence time of water in flood-prone areas, although without significant variations in water levels due to the low slope of the terrain. Furthermore, natural storage in depressions, wetlands, and low-lying areas was found to attenuate outflows, highlighting the importance of preserving these environments as a key component of water management in lowland basins.

Keywords – Plain Hydrology, Road Infrastructure, Hydrological Modeling, HEC-HMS.

1. Introducción

Las cuencas hidrográficas del Chaco argentino se desarrollan en una extensa planicie sedimentaria, caracterizada por pendientes muy suaves, en general inferiores a 50 cm/km [1], que condicionan el escurrimiento, con frecuentes anegamientos y acumulaciones temporales en depresiones naturales.

Este fenómeno de anegamiento se ve agravado por la expansión de infraestructuras que alteran el flujo natural, una tendencia que ha sido vinculada recientemente al ascenso de los niveles freáticos y cambios en el uso del suelo en las llanuras argentinas [2]; en este contexto, la infraestructura vial actúa como una barrera física que redefine la conectividad hidrológica del sistema.

Esta morfología genera una hidrodinámica particular donde los excedentes pluviales tienden a almacenarse en esteros, cañadas y paleocauces antes de integrarse a la red de drenaje mayor. Según [3] la llanura chaqueña no constituye un espacio homogéneo, sino que presenta una compleja combinación de humedales, planicies de inundación y sectores de drenaje deficiente, lo que explica la persistencia de fenómenos de inundación aún bajo precipitaciones moderadas.

[4] aborda al entendimiento de la dinámica del agua superficial en zonas rurales, propensas a inundarse y con la napa freática poco profunda (como el caso que nos ocupa) y, aunque el sesgo es hacia el uso agrícola, describe quienes son los generadores de inundación y su impacto.

La cuenca del arroyo Polvorín –Palometa se ubica en el sector centro-oriental de la provincia del Chaco y se desarrolla íntegramente dentro de su territorio, con una superficie de aproximadamente 5.100 km². Sus nacientes se localizan en el centro-oeste de la provincia, desde donde drena en dirección predominante noroeste-sudeste.

El sistema está conformado por los arroyos Polvorín y Palometa, que convergen hacia cursos de mayor jerarquía vinculados al río Paraná, por lo que constituye una cuenca exorreica dentro de los denominados ríos del Chaco oriental. La hidrodinámica del área está fuertemente condicionada por la morfología de planicie: el escurrimiento superficial es lento y se combina con procesos de infiltración y almacenamiento en bajos naturales, generando extensos anegamientos temporales tras eventos de precipitación intensa.

Esta dinámica convierte a la cuenca en un sistema regulador de los excedentes hídricos regionales, donde los esteros y cañadas cumplen un papel clave en la atenuación de los caudales de crecida.

La particular hidrodinámica de la cuenca Polvorín–Palometa, caracterizada por su baja energía de relieve [5] y un escurrimiento superficial lento, con frecuentes almacenamientos intermedios, la convierte en un sistema altamente sensible a la interacción con la infraestructura vial.

En este contexto, la red de caminos rurales y carreteras constituye un factor crítico: aun pequeñas obstrucciones o discontinuidades en el drenaje natural pueden modificar significativamente variables hidrológicas de interés tales como la extensión de las manchas de inundación o la altura de la lámina de agua en zonas bajas.

Esta condición que resalta la vulnerabilidad del sistema frente a obras lineales que interfieren con el flujo y justifica la necesidad de analizar con detalle la relación entre la hidrodinámica de la cuenca y las estructuras de comunicación que la atraviesan.

El camino Guayaibí sintetiza esta problemática: su trazado, al interrumpir parcialmente la continuidad del drenaje, se convierte en un punto crítico que condiciona la propagación de las inundaciones (Fig. 1). Así, el análisis de este caso permite vincular la hidrodinámica general de la cuenca con los efectos locales que producen las obras viales, constituyéndose en un escenario idóneo para evaluar de manera integrada los procesos hidrológicos y la infraestructura rural.

En efecto, durante el evento de precipitaciones extraordinarias registrado el 6 de mayo de 2025, se produjeron anegamientos significativos que impidieron el libre escurrimiento de las aguas y generaron inundaciones en sectores urbanos de Machagai situados aguas arriba.

2. Objetivos

El objetivo de este trabajo es analizar el impacto hidrológico que genera la infraestructura vial rural sobre la dinámica de la cuenca Polvorín–Palometa (Fig. 1), tomando como caso de estudio el camino Guayaibí. Se busca evaluar de qué manera la presencia de esta vía de comunicación modifica las condiciones naturales de escurrimiento y cuáles son las consecuencias hidrológicas derivadas de

su interacción dentro de una planicie de escasa pendiente regional, con especial énfasis en variables críticas, como la extensión de las áreas anegadas y los niveles de lámina de agua aguas arriba del camino.




Fig. 1. Ubicación general de la zona de estudio.

3. Materiales y Métodos

Se desarrolló una metodología basada en la construcción de un modelo hidrológico representativo de la cuenca, a partir de sus parámetros morfométricos, condiciones de uso del suelo y precipitaciones de diseño, donde el modelo se implementó en el entorno del programa HEC-HMS, lo que permitió reproducir, en condiciones controladas, el comportamiento del sistema ante distintos escenarios. Se analizaron alternativas con y sin adecuaciones hidráulicas en el camino, considerando principalmente la incorporación de obras de paso (alcantarillas) y reservorios de retención.

Este enfoque permitió comparar la respuesta hidrológica de la cuenca frente a la infraestructura vial, aportando una base técnica para el diseño de medidas que mitiguen los efectos de la obstrucción del escurrimiento natural.

El análisis hidrológico se realizó mediante el modelo HEC-HMS (*Hydrologic Modeling System*), desarrollado por el *Hydrologic Engineering Center* (HEC) del *US Army Corps of Engineers*, que permite representar la transformación lluvia–escorrentía en cuencas hidrográficas.

Para ello, se delimitó la cuenca de aporte al camino Guayaibí, determinando su superficie de drenaje y parámetros característicos. El volumen de escorrentía se estimó mediante el método del *Soil Conservation Service* (SCS), que relaciona la precipitación con el número de curva (CN) [6], obtenido

a partir de una clasificación supervisada de imágenes satelitales Sentinel para discriminar los usos del suelo y las coberturas.

El tiempo de concentración de la cuenca se calculó en función de la pendiente media y la longitud hidráulica, lo que permitió generar, con el modelo, el hidrograma de aporte al camino bajo distintos escenarios de precipitación.

Así, el procedimiento incluyó las siguientes etapas:

3.1. Delimitación de la cuenca de aporte

La delimitación de la cuenca que descarga hacia el camino Guayaibí se realizó mediante interpretación de imágenes satelitales y curvas de nivel obtenidas de cartografía digital, lo que permitió identificar las divisorias de aguas y estimar la superficie de aporte, de aproximadamente 202,2 km², correspondiente a una subcuenca del sistema Polvorín–Palometa (Fig. 2).




Fig. 2. Cuenca de aporte identificada a través de imagen satelital (fuente: Copernicus).

Sin embargo, debe señalarse que, en el contexto de la llanura chaqueña, los parteaguas no se presentan de manera definida, lo que favorece la ocurrencia de transfluencias uni y bidireccionales entre cuencas vecinas. Esto implica que el área de aporte no constituye un límite fijo, sino que puede variar dinámicamente en función de la intensidad y distribución espacial de las precipitaciones, el estado de humedad antecedente de los suelos y los niveles de agua en esteros y cañadas durante los distintos períodos [5].

3.2. Hidrodinámica de la cuenca de estudio

Se analizaron las zonas de acumulación y de obstaculización a través de imágenes satelitales Sentinel-2 L2A, en fechas previas a la precipitación y posteriores a la misma, evidenciándose el efecto que produce el camino y que impide el escurrimiento natural del agua.

Se analizaron imágenes desde el 30 de abril hasta el 24 de junio de 2025, con la combinación de bandas B8A-B11-B04, con el fin de resaltar los cuerpos de agua. Luego, se realizó una clasificación supervisada de las imágenes satelitales para observar el avance de los cuerpos de agua, con el fin de identificarlos claramente y evaluar los resultados de los trabajos de limpieza ejecutados, tal como puede observarse en la Fig. 3.




Fig. 3. Avance de las manchas de inundación durante las precipitaciones de mayo de 2025.

3.3. Evaluación de precipitaciones de diseño

Se utilizaron registros pluviométricos diarios de la localidad de Machagai, con los cuales se realizó el análisis probabilístico de lluvias mediante el programa AF-MULTI, considerando distribuciones teóricas (Log-Gauss, Gumbel, GEV, Pearson, Log-Pearson, Exponencial y Wakeby).

Se evaluaron los Errores Cuadráticos Medios de Frecuencia (ECMF) y el Error Cuadrático Medio de Variable (ECMV) y se adoptó el modelo de Gumbel dado que se presentó considerablemente menor en el ECMF (62% menor) y solo 3% mayor en el ECMV (Tabla 1). Y se determinaron las precipitaciones de diseño asociadas a tiempos de recurrencia de 2 y 5 años (Tabla 2).

Tabla 1. Errores de cada método.

	LOGGAUSS	GUMBEL	GEV	PEARSON	LOGPEARSON	EXPONENC.	WAKEBY
ECMF	0,029	0,0259	0,0215	0,0227	0,0364	0,068	0,068
ECMV	8,03	7,77	8,09	8,72	11,37	7,56	7,56

Tabla 2. Precipitaciones máximas diarias de cada método y su tiempo de recurrencia.

TR (años)	LOGGAUSS	GUMBEL	GEV	PEARSON	LOGPEARSON	EXPONENC.	WAKEBY
2	91,1	91,8	93,4	95,1	96,7	86,1	94,6
5	126,5	127,1	128,8	129,8	134,2	122,6	125,7

3.4. Determinación del uso del suelo y Curva Número (CN)

A partir del análisis de la imagen Sentinel 2B del 10 de marzo de 2025 y de observaciones complementarias en campo, se identificaron y clasificaron los principales usos y coberturas del suelo en la cuenca de aporte, a saber:

- Agricultura de media cobertura: zonas con cultivos de mayor densidad y desarrollo, lo que incrementa la capacidad de retención del suelo.
- Agricultura de baja cobertura: sectores con cultivos menos desarrollados, con mayor predisposición al escurrimiento superficial.
- Bajos: áreas correspondientes a depresiones naturales o paleocauces, identificadas por manchas de agua en imágenes satelitales, donde suelen producirse almacenamientos temporales.
- Montes: sectores con vegetación densa, sin intervención antrópica, que presentan altos niveles de infiltración.

A partir una clasificación supervisada de la imagen satelital, se discretizaron estos tipos de coberturas en la cuenca de estudio (Fig. 4). A cada categoría se le asignó un valor de CN (Tabla 3), con el fin de caracterizar la infiltración y la escorrentía directa en la modelación hidrológica.

Determinado el valor de CN, este fue ajustado a condiciones de humedad antecedente tipo III, conforme a lo prescripto por el método (Ecuación 1) y empleado posteriormente en el proceso de modelación hidrológica.

$$CN(III) = \frac{23 * CN(II)}{10 + 0,13 * CN(II)} = \frac{23 * 38}{10 + 0,13 * 38} = 59 \quad (1)$$




Fig. 4. Clasificación de uso de suelos en sub cuenca.

Tabla 3. Áreas de uso dentro de la cuenca y CN asignado para cada uso.

Zona	Área (km ²)	Porción (en %)	CN asignado	CN ponderado
Monte	31,1	15	31	5
Cultivos media cobertura	69,3	34	35	12
Cultivos baja cobertura	58,6	29	38	11
Bajos	43,2	21	50	11
Total	202,2	99		38

3.5. Estimación del tiempo de concentración

Se aplicó la fórmula de retardo propuesta por el *Soil Conservation Service* (SCS, 1973), lo que permitió estimar el tiempo de concentración de la cuenca en función de su pendiente, longitud hidráulica y CN ponderada (Ecuación 2).

$$tc = 3,42 \cdot \left(\frac{1000}{CN} - 0,9 \right)^{0,7} \cdot L^{0,8} \cdot S^{-0,5} = 982 \text{ min} \quad (2)$$

Donde:

tc = tiempo de concentración de la cuenca (minutos);

CN = número de curva del *Soil Conservation Service* (adimensional) = 59;

L = longitud hidráulica máxima del escurrimiento superficial (km) = 40,4 km;

S = pendiente media de la cuenca (m/m) = 0,0002 m/m.

3.6. Modelación hidrológica

Se implementó el modelo HEC-HMS (*Hydrologic Engineering Center – Hydrologic Modeling System*) para la simulación de la transformación lluvia-caudal, empleando el método del SCS. El

esquema de modelación se estructuró en dos componentes principales: la cuenca de aporte, responsable de generar los excedentes hídricos a partir de las precipitaciones y el embalse producido por el camino Guayaibí, que actúa como regulador, atenuando los caudales resultantes. El paso de tiempo adoptado para la precipitación y el hidrograma de escurrimiento superficial fue de un día, debido a la dificultad de la toma de datos de lluvia que, generalmente, son diarios y además fue calculado el tiempo de concentración, mayor a 16h, sumado a los almacenamientos en cuerpos receptores, se aproximan a 24h, motivo por el cual se adoptó dicho valor como apropiado.

Este modelo ha demostrado una alta eficacia en variados estudios simulando eventos de precipitación - escurrimiento en cuencas con baja energía de relieve, permitiendo también evaluar la respuesta de subcuencas ante alteraciones físicas en el terreno con gran precisión [7], [8].

La simplicidad conceptual y operativa del modelo garantiza su aplicabilidad en otras zonas de la provincia, siempre considerando las particularidades de cada caso. En la Fig 5 se presenta el esquema de modelación adoptado.




Fig. 5. Esquema de modelación utilizado.

En lo referido al componente del reservorio, el modelo se parametrizó a partir de dos insumos fundamentales. En primer lugar, la relación entre la altura de la lámina de agua y la superficie inundada, que permitió representar el comportamiento volumétrico del embalse en función de los niveles alcanzados.

En segundo lugar, se definió la curva de control de salida de caudales, estableciendo para distintas alternativas de simulación las correspondencias entre altura de lámina y caudal de descarga. Estos elementos posibilitaron reproducir en la modelación el efecto regulador del reservorio sobre los excedentes hídricos generados por la cuenca de aporte.

Para la definición de la relación entre altura de lámina de agua y superficie inundada, se recurrió al análisis de imágenes satelitales a partir de las cuales se delimitaron las áreas efectivamente anegadas durante eventos críticos (Fig. 6). Con esta base se estimaron alturas máximas de almacenamiento, considerando la correspondencia entre superficie afectada y nivel de agua.

La altura máxima adoptada fue de 30 cm, valor coherente con las pendientes suaves y las condiciones geomorfológicas características de la llanura chaqueña, que condicionan tanto la extensión como la permanencia de los anegamientos (Tabla 4).

Para la construcción de las curvas de descarga del reservorio se analizaron dos escenarios: (i) sin camino Guayaibí (sin influencia antrópica), donde la descarga se representó como flujo natural sobre la red de drenaje, obteniendo la Ecuación 3; y (ii) con proyecto (camino existente), donde se modeló la presencia del terraplén con diez alcantarillas circulares de $D = 0,60$ m, construyendo la curva de descarga como la suma de los caudales unitarios por conducto, bajo un régimen de “flujo tipo 3”, conforme a la clasificación de [9].




Fig. 6. Área del reservorio proyectado en margen aguas arriba del camino.

Tabla 4. Altura de lámina vs Áreas Inundadas.

Lámina de agua (m)	Área Inundada (ha)
0,00	0
0,10	727,8
0,20	1.455,6
0,30	2.205,4

Para esta alternativa se empleó una ecuación simplificada para el gasto a través de las alcantarillas, despreciando las pérdidas por fricción en el interior del conducto, tal como se expone en la Ecuación 4.

En la Fig. 7 se puede observar las curvas de descarga utilizadas para ambos escenarios de simulación.

$$Q = \frac{1}{n} \cdot B \cdot h^{5/3} \cdot i^{1/2} \quad (3)$$

$$Q = N \cdot Cd \cdot Ac \cdot \sqrt{2g \cdot h} \quad (4)$$

Donde:

Q : caudal de salida (m^3/s);

n : coeficiente de rugosidad = $0,015 \text{ s/m}^{1/3}$;

B : ancho del escurrimiento = 2.300 m ;

h : tirante de agua (m);

i : pendiente del flujo = $0,00015 \text{ m/m}$;

N : número de alcantarillas = 10 ;

Cd : coeficiente de descarga de las alcantarillas = $0,7$;

Ac : sección mojada en el ingreso a la alcantarilla;

g : aceleración de la gravedad = $9,81 \text{ m/s}^2$.




Fig. 7. Curvas de descarga del reservorio utilizadas para los escenarios de simulación.

4. Análisis de Resultados

En las Figs. 8 a 11 se sintetizan los resultados obtenidos a partir de la modelación hidrológica realizada para los escenarios definidos en la metodología. Dichos escenarios contemplan precipitaciones de diseño con tiempos de recurrencia de 2 y 5 años, evaluando la respuesta hidrológica tanto en condiciones naturales como bajo la influencia del camino Guayaibí.

En las Figs. se observan los hidrogramas de entrada y salida al embalse, así como las variaciones de nivel generadas dentro del mismo, lo que permite comparar el comportamiento del sistema frente a diferentes condiciones de recurrencia y de infraestructura.




Fig. 8. Resultados del modelo – Escenario sin camino – TR=2 años.




Fig. 9. Resultados del modelo – Escenario sin camino – TR=5 años.




Fig. 10. Resultados del modelo – Escenario con Proyecto – TR=2 años.




Fig. 11. Resultados del modelo – Escenario con Proyecto – TR=5 años.

En virtud de los resultados obtenidos, se advierte que la presencia del camino Guayaibí, aun contemplando la correcta adecuación hidráulica mediante la disposición de diez alcantarillas, produce inevitablemente una reducción en los caudales de salida de la cuenca.

Esta disminución en la descarga se traduce en un mayor tiempo de permanencia de las aguas en las áreas anegables, lo que prolonga los períodos de inundación aguas arriba del camino. Además, los

niveles de altura de agua dentro del embalse no presentan variaciones significativas entre escenarios, lo cual responde a la escasa pendiente y a la reducida variabilidad del relieve propio de la cuenca.

En la Tabla 5 se detallan los caudales pico de salida (Q_p) y tirantes máximos (h_{max}) arrojados por el modelo ante distintos escenarios de modelación.

Tabla 5. Análisis comparativo de los resultados de la simulación

TR	Escenario			
	Sin Camino		Con Proyecto	
	Q_p (m ³ /s)	h_{max} (m)	Q_p (m ³ /s)	h_{max} (m)
2 años	4,73	0,11	0,53	0,13
5 años	7,24	0,14	0,83	0,17

5. Conclusiones

El análisis desarrollado permitió caracterizar la particular hidrodinámica de la cuenca Polvorín–Palometa, representativa de muchas cuencas del interior chaqueño.

La morfología de planicie, con pendientes mínimas y una marcada propensión al almacenamiento intermedio en esteros y cañadas condiciona el escurrimiento superficial lento, con elevada permanencia de los excedentes hídricos. Esta condición explica la alta sensibilidad del sistema frente a la presencia de infraestructuras lineales, como caminos y terraplenes.

La metodología aplicada, basada en la combinación de información satelital, estimación de precipitaciones de diseño y modelación hidrológica con HEC-HMS, demostró ser sencilla de implementar y fácilmente replicable en otras áreas de la provincia.

A pesar de su simplicidad conceptual, los resultados obtenidos reflejan con verosimilitud la dinámica del sistema y constituyen una herramienta útil para el análisis preliminar de alternativas de intervención.

Los resultados de la modelación ponen de manifiesto que la infraestructura vial incide principalmente sobre los caudales de descarga y sobre el tiempo de permanencia de las aguas dentro de la cuenca, incluso con una adecuada disposición hidráulica de alcantarillas. Se registra una reducción de los caudales de salida y en consecuencia, incremento en la duración de los anegamientos.

Sin embargo, se observa que las variaciones en los niveles de lámina de agua son mínimas, lo que se vincula a la escasa pendiente y la homogeneidad del relieve. De este modo, una adecuada planificación hidráulica de las obras permite mitigar variaciones bruscas en los niveles de almacenamiento, aunque no evita del todo los efectos sobre la dinámica de descarga y la persistencia de inundaciones.

Los resultados también evidencian que la presencia de almacenamiento de agua en cañadas, esteros y zonas bajas de la cuenca genera, de manera inevitable, una atenuación de los caudales de salida.

Esta función de regulación natural resalta la importancia de preservar dichos ambientes en la gestión de las cuencas de llanura, ya que su conservación resulta clave para reducir los impactos de los eventos de crecida y asegurar un manejo más eficiente y sostenible de los recursos hídricos.

Referencias

- [1] Manoilloff, R., Rey, H. y Pérez, M. (2007). Atlas Geográfico de la Provincia del Chaco. Tomo I: El Medio Natural. Instituto de Geografía, Facultad de Humanidades, UNNE, Resistencia.
- [2] Kuppel, S., et al. (2015). The evolution of river network and floodplains in the Anthropocene: insights from the Argentine Pampas. Hydrology and Earth System Sciences.

- [3] Bruniard, E. D. (1975). El Gran Chaco argentino: ensayo de interpretación geográfica. Universidad Nacional del Nordeste. Resistencia. Editorial EUDENE.
- [4] Cappelletti, L. M. (2024). Agua superficial de las llanuras del núcleo agroproductivo de Argentina: análisis basado en múltiples líneas de evidencia Tesis presentada para optar al título de Doctor en, Universidad de Buenos Aires, Argentina.
- [5] Caamaño Nelli, G., Fertonani, M., Prendes, H., Quinodoz, H. (1979). Análisis de sistemas hidrológicos no típicos- Bases teóricas y criterios metodológicos. Universidad Nacional del Litoral, Santa Fe. Argentina.
- [6] Orsolini, H. E., Zimmermann, E. D. y Basile, P. A. (2017). *Hidrología, Procesos y Métodos*. UNR Editora, cuarta edición, Rosario, Santa Fe, Argentina.
- [7] Feldman, A. D. (2021). Hydrologic Modeling System HEC-HMS: Technical Reference Manual. US Army Corps of Engineers, Institute for Water Resources.
- [8] Azmat, M., et al. (2016). Hydrological modeling to simulate response of highly glacierized catchment to climate change. Journal of Hydrology. (Validación de la capacidad predictiva de HEC-HMS en escenarios de cambio).
- [9] Bodhaine, G. L. (1968). Measurement of Peak Discharge at Culverts by Indirect Methods. Techniques of Water-Resources Investigations of the U.S. Geological Survey, Book 3, Chapter A3. Washington, DC: U.S. Government Printing Office.

Desafíos y Oportunidades de Ingeniería de Requerimientos asistida por LLM y Prompt Engineering

Fernando Corinaldesi^{1,2} , Hernán Ariel Domínguez^{1,2} , Briant Alcides Gauna^{3,4,*} 

¹ Universidad Nacional de José C. Paz. Departamento de Economía, Producción e Innovación Tecnológica. Buenos Aires, Argentina.

² Universidad Nacional de La Plata. Facultad de Informática. Buenos Aires, Argentina.

³ Universidad Nacional de Misiones-CONICET. Facultad de Ingeniería. Instituto de Materiales de Misiones (IMAM) Grupo de Investigación y Desarrollo en Electrónica (GIDE). Misiones, Argentina.

⁴ Universidad del Gran Rosario. Espacio de Diseño y Tecnologías. Rosario, Argentina.

e-mails: fernando.corinaldesi@docentes.unpaz.edu.ar, dhariel2904@gmail.com, br.gauna@fio.unam.edu.ar

Resumen

En el campo del desarrollo de software, la ingeniería de requisitos y la interacción con modelos de lenguaje como ChatGPT están ganando cada vez más relevancia. Este estudio explora la intersección entre los requerimientos de software y las técnicas de *prompt engineering* utilizadas con ChatGPT. A través de un mapeo sistemático de la literatura, se identifican los principales desafíos y oportunidades en la aplicación de ChatGPT para la elicitación, análisis y gestión de requerimientos. Los resultados destacan la importancia de desarrollar *prompts* efectivos para obtener información precisa y relevante de ChatGPT en el contexto de la ingeniería de requisitos.

Palabras Clave – Ingeniería de Software, Ingeniería de Requerimientos, ChatGPT, LLM, Ingeniería de Prompts, Desafíos, Beneficios, Oportunidades, Mapeo Sistemático.

Abstract

In the field of software development, requirements engineering and interaction with language models such as ChatGPT are gaining increasing relevance. This study explores the intersection between software requirements and prompt engineering techniques used with ChatGPT. Through a systematic mapping of the literature, the main challenges and opportunities in applying ChatGPT for requirements elicitation, analysis, and management are identified. The results highlight the importance of developing effective prompts to obtain accurate and relevant information from ChatGPT in the context of requirements engineering.

Keywords – Software Engineering, Requirements Engineering, ChatGPT, LLM, Prompt Engineering, Challenges, Benefits, Opportunities, Systematic Mapping.

1. Introducción

En los últimos años, los avances en el procesamiento del lenguaje natural (NLP) han allanado el camino para aplicaciones transformadoras en diversos ámbitos [1], como la atención médica, las finanzas, el comercio electrónico y las redes sociales. Entre estos avances, los modelos de lenguaje de gran escala (*Large Language Models*, LLMs) han surgido como herramientas poderosas con el potencial de revolucionar las prácticas de ingeniería de software. Una de las áreas que está experimentando un cambio significativo es la ingeniería de requisitos, especialmente con la introducción de modelos de lenguaje como ChatGPT [2].

ChatGPT es un chatbot de IA construido utilizando los modelos de lenguaje de gran escala (LLMs) de OpenAI, como GPT-4 y versiones anteriores [3]. Ha establecido nuevos estándares (tareas, métricas, etc.) en inteligencia artificial al demostrar la capacidad de las máquinas para comprender las complejidades del lenguaje y la comunicación humana.

Por otro lado, los requisitos de Software pueden definirse como descripciones de cómo debería comportarse el sistema o de una propiedad o atributo del sistema. Estos se definen durante las primeras etapas del desarrollo de un sistema como una especificación de lo que debe implementarse [4]. El área de la ingeniería de software encargada de esta tarea se conoce como “Ingeniería de requisitos”.

La ingeniería de requisitos es un término relativamente nuevo que se ha inventado para abarcar todas las actividades involucradas en descubrir, documentar y mantener un conjunto de requisitos para un sistema basado en computadora. El uso del término "ingeniería" implica que se deben utilizar técnicas sistemáticas y repetibles para asegurar que los requisitos del sistema sean completos, consistentes, relevantes [4]. Sin embargo, en la práctica, la ingeniería de requisitos enfrenta diversos desafíos y problemas:

- Los requisitos no reflejan las necesidades reales del cliente para el sistema.
- Los requisitos son inconsistentes y/o están incompletos.
- Es costoso realizar cambios en los requisitos después de que se han acordado.
- Hay malentendidos entre los clientes, los que desarrollan los requisitos del sistema y los ingenieros de software que desarrollan o mantienen el sistema [4].

La introducción de tecnologías de IA, particularmente los modelos de lenguaje de gran escala como ChatGPT, ofrece nuevas oportunidades para abordar estos desafíos [2].

Sin embargo, para aprovechar eficazmente estas herramientas, es necesario dominar lo que se conoce como "*prompt*", esto se debe a que la calidad de la salida generada por un modelo de lenguaje depende en gran medida del *prompt* que recibió. Los *prompts*, en este contexto, pueden ser, por ejemplo, una frase, una pregunta o una instrucción dada al modelo en lenguaje natural [5].

Dado este contexto, emerge como disciplina, la Ingeniería de *Prompts* (PE, por sus siglas en inglés), la cual es un proceso que se centra en crear, optimizar y refinar *prompts* para garantizar la relevancia y calidad de la salida, que abarca la generación de información que se alinea con el propósito previsto y es lingüísticamente sólida. El uso de PE puede fortalecer la calidad de lo que un modelo de lenguaje interpreta, así como cualquier salida generada [6]. Para los LLMs, la PE es esencial, ya que la profunda comprensión lingüística de los LLMs plantea un desafío en la formulación de *prompts* de alta calidad, lo que a su vez afecta la calidad de cualquier salida generada.

El uso de la ingeniería de *prompts* (PE) potencia las capacidades de los LLMs para resolver tareas de procesamiento del lenguaje natural (NLP) a un nivel más avanzado. Dado que el procesamiento del lenguaje natural ha sido, y sigue siendo, utilizado para tareas de ingeniería de requisitos (RE), mientras que el lenguaje natural sigue siendo un componente central de la ingeniería de requisitos, surgió la idea de utilizar la ingeniería de *prompts* para los LLMs en la ingeniería de requisitos. Sin embargo, para que los LLMs sean útiles dentro de la ingeniería de requisitos, deben adquirir conocimientos sobre las actividades de ingeniería de requisitos y aprender el contexto aplicado [7].

Este estudio se centra en explorar cómo ChatGPT y las técnicas de *prompt engineering* pueden aplicarse en el contexto de la ingeniería de requisitos. Buscamos identificar las oportunidades que estas tecnologías ofrecen para mejorar la elicitación, análisis y gestión de requerimientos, así como

los desafíos que presentan. Además, investigamos las mejores prácticas emergentes en el uso de estas tecnologías para la ingeniería de requisitos.

La relevancia de esta investigación se fundamenta en la creciente adopción de tecnologías de IA en el desarrollo de software y la necesidad de comprender cómo estas herramientas pueden mejorar los procesos existentes. Al explorar la intersección entre la ingeniería de requisitos y las capacidades de ChatGPT, este estudio busca contribuir al cuerpo de conocimiento en ambos campos y proporcionar orientación práctica para los profesionales del software.

2. Metodología Aplicada

Con el fin de cumplir con los objetivos planteados, este estudio adopta un enfoque de mapeo sistemático de la literatura [11]. Este tipo de estudio permite obtener una visión global del estado actual de la investigación en un campo específico, identificando, clasificando y organizando los trabajos existentes en categorías previamente definidas.

El procedimiento seguido comprende la definición de preguntas de investigación, la búsqueda sistemática de literatura, la aplicación de criterios de inclusión y exclusión, la selección de estudios relevantes y la posterior organización y síntesis de la información a partir de un esquema de clasificación basado en palabras clave.

2.1. Definición de Preguntas de Investigación

El primer paso del mapeo sistemático consistió en la definición de un conjunto de preguntas de investigación, las cuales orientaron tanto la estrategia de búsqueda como el posterior proceso de clasificación y análisis de los estudios seleccionados.

Las preguntas de investigación se enfocan en comprender cómo los modelos de lenguaje de gran escala (LLMs), como ChatGPT, pueden contribuir a distintas actividades de la ingeniería de requerimientos, particularmente en la creación, análisis y validación de requerimientos de software.

Las preguntas clave formuladas fueron:

(PC1) ¿Cómo puede ChatGPT ayudar en la creación de requerimientos de software?

(PC2) ¿Qué desafíos presenta el uso de *prompts* para obtener información clara sobre los requerimientos?

(PC3) ¿Cómo se pueden mejorar los *prompts* para obtener mejores respuestas sobre los requerimientos?

(PC4) ¿Qué tan precisa es la información que proporciona ChatGPT al usar *prompts* sobre requerimientos?

2.2. Estrategia de Búsqueda

Se llevó a cabo una búsqueda sistemática de artículos a través de la plataforma IEEE Xplore, con el objetivo de identificar estudios relevantes sobre el uso de modelos de lenguaje de gran escala y/o ChatGPT en la ingeniería de requerimientos. De manera complementaria, se realizó una búsqueda adicional en la base de datos ACM Digital Library, con el propósito de reducir posibles sesgos de publicación y ampliar la cobertura de trabajos relevantes en el ámbito de la ingeniería de software.

En ambos casos, los artículos recuperados fueron evaluados de acuerdo con los criterios de inclusión y exclusión definidos. Aquellos estudios que no cumplían con dichos criterios, ya sea por falta de relevancia directa con la temática o por limitaciones de acceso al texto completo, fueron descartados.

2.3. *Criterios de Inclusión y Exclusión*

Con el objetivo de asegurar la relevancia y coherencia del corpus analizado, se definieron criterios de inclusión orientados a seleccionar estudios directamente vinculados con el uso de modelos de lenguaje de gran escala en el contexto de la ingeniería de requerimientos.

Se incluyeron aquellos estudios (***criterios de inclusión***) que:

a) Abordan el uso de modelos de lenguaje de gran escala (LLMs), tales como ChatGPT, GPT-3 u otros modelos similares, en el ámbito de la ingeniería de software, con énfasis en actividades relacionadas con la creación, elicitación o análisis de requerimientos de software.

b) Analizan el uso de *prompts* o técnicas de ingeniería de *prompts* para interactuar con modelos de lenguaje con el fin de obtener o procesar información asociada a requerimientos de software.

c) Evalúan aspectos vinculados con la precisión, los desafíos o las oportunidades en la interacción con modelos como ChatGPT dentro del contexto de la ingeniería de requerimientos.

d) Corresponden a publicaciones académicas revisadas por pares, tales como artículos científicos presentados en conferencias, *journals* o *workshops* relevantes en ingeniería de software y procesamiento de lenguaje natural.

e) Han sido publicados en los últimos cinco años, con el fin de reflejar el estado actual de las tecnologías basadas en LLMs.

f) Se encuentran disponibles en idioma inglés o español.

g) Han sido recuperados a partir de las búsquedas realizadas en IEEE Xplore y ACM Digital Library.

De manera complementaria, se definieron ***criterios de exclusión*** para descartar estudios que no se ajustaran al foco del mapeo sistemático. Se excluyeron aquellos trabajos que:

a) No abordan el uso de modelos de lenguaje de gran escala en el contexto de la ingeniería de requerimientos, o que se centran exclusivamente en dominios distintos (por ejemplo, *marketing*, atención al cliente o educación).

b) Analizan técnicas de inteligencia artificial o procesamiento del lenguaje natural sin considerar el rol de los *prompts* o su aplicación en ingeniería de requerimientos.

c) Han sido publicados con anterioridad al período temporal definido.

d) Se encuentran redactados en idiomas distintos del inglés o español.

e) No cuentan con acceso al texto completo o cuyo resumen no incluye términos clave relacionados con ChatGPT, ingeniería de *prompts*, desafíos u oportunidades en ingeniería de requerimientos.

2.4. *Proceso de Selección de Estudios*

El proceso de selección de estudios se llevó a cabo en múltiples etapas secuenciales, con el objetivo de identificar un conjunto de trabajos relevantes y coherentes con el alcance del mapeo sistemático.

En una primera etapa, se identificaron los estudios potenciales a partir de las búsquedas realizadas en las bases de datos seleccionadas. En esta fase inicial, se recuperaron todos los trabajos que coincidían con la cadena de búsqueda definida.

En una segunda etapa, se realizó un filtrado preliminar basado en la lectura de los títulos y resúmenes, con el fin de descartar aquellos estudios que no cumplían con los criterios de inclusión establecidos o que resultaban claramente irrelevantes para el foco del estudio.

Los trabajos que superaron esta etapa fueron sometidos a una evaluación completa, mediante la revisión detallada de su contenido, incluyendo introducción, metodología, resultados y conclusiones, a fin de verificar su alineación con los objetivos del mapeo.

Finalmente, los estudios seleccionados fueron considerados para la extracción y síntesis de información relevante, permitiendo identificar desafíos, oportunidades, enfoques metodológicos y líneas de investigación emergentes en el uso de modelos de lenguaje de gran escala y técnicas de *prompt engineering* en la ingeniería de requerimientos.

La Fig. 1 resume de manera gráfica las principales etapas del proceso de selección y organización de los estudios incluidos en el mapeo sistemático.

La cadena de caracteres usada para realizar el filtro y búsqueda es:

("ChatGPT" OR "GPT-3" OR "Large Language Models" OR "LLMs") AND ("software requirements" OR "requirements engineering" OR "elicitation of requirements" OR "prompt engineering" OR "prompt design") AND ("accuracy" OR "precision" OR "challenges" OR "improvement")




Fig. 1. Resumen del Mapeo Sistemático.

3. Estado de la Ingeniería de Requerimientos

A partir del análisis de los estudios seleccionados en el mapeo sistemático, se observa que la ingeniería de requerimientos (ER) es una disciplina clave dentro del desarrollo de software, centrada en definir y documentar las funcionalidades y comportamientos que un sistema debe cumplir para satisfacer las necesidades de sus usuarios.

3.1. Avances en la Automatización de la Ingeniería de Requisitos

Los estudios analizados en el mapeo sistemático evidencian que, en los últimos años, la automatización en la ingeniería de requerimientos ha ganado impulso, mediante el desarrollo de herramientas y técnicas orientadas a mejorar la calidad de los requisitos. Se han desarrollado herramientas y técnicas para mejorar la calidad de los requisitos mediante el uso de métodos como la validación formal, la verificación automática y los análisis de ambigüedad. Estos enfoques buscan minimizar los defectos antes de que los requisitos lleguen a las etapas de diseño y desarrollo.

La introducción de los modelos de lenguaje de gran escala, como GPT-3 y GPT-4, ha traído nuevas posibilidades al campo de la ingeniería de requisitos. Estos modelos, entrenados con grandes cantidades de datos textuales, son capaces de comprender y generar lenguaje natural, lo que los convierte en herramientas prometedoras para asistir en la detección de defectos en los documentos de requisitos.

Estudios recientes han evaluado empíricamente el desempeño de GPT-4 en tareas vinculadas al análisis estructural de artefactos asociados a requisitos, observándose que el modelo alcanza niveles cercanos a la corrección total en tareas formales basadas en reglas y estructuras lógicas predefinidas, aunque su rendimiento disminuye cuando se requiere interpretación semántica profunda o razonamiento contextual complejo [9]. Esta distinción resulta particularmente relevante en ingeniería de requerimientos, donde numerosos defectos surgen de ambigüedades conceptuales más que de errores sintácticos. Desde una perspectiva arquitectónica, además, la integración de modelos generativos en pipelines de análisis automático introduce nuevos puntos críticos de fallo, tales como segmentación inadecuada de documentos, deficiencias en el ranking semántico y persistencia de alucinaciones aun cuando la información relevante ha sido correctamente recuperada [10], lo que evidencia que la efectividad de la automatización no depende únicamente del modelo sino del diseño integral del sistema. En este contexto, también se han propuesto mecanismos de *structured requirement binding*, que incorporan identificadores estructurados y restricciones declarativas dentro del prompt para preservar la alineación semántica y facilitar la trazabilidad entre requisitos y artefactos generados [11], planteando una evolución hacia enfoques donde la trazabilidad se integra explícitamente en el proceso generativo.

3.2. Aplicación de IA en la Ingeniería de Requisitos

En relación con la precisión y confiabilidad de los modelos de lenguaje, uno de los ejes abordados en las preguntas de investigación, diversos estudios señalan que los LLMs, como ChatGPT, pueden ofrecer capacidades avanzadas para comprender el contexto y detectar defectos en los requerimientos. El uso de inteligencia artificial (IA) en la ingeniería de requisitos no es nuevo, pero los avances recientes en modelos de lenguaje han superado los enfoques anteriores. Tradicionalmente, las herramientas de procesamiento de lenguaje natural (NLP) se centraban en la detección de palabras clave o la implementación de reglas predefinidas para identificar posibles defectos en los documentos. Sin embargo, estos enfoques carecían de flexibilidad y no podían captar los matices del lenguaje natural. Investigaciones recientes han demostrado que los LLMs, como ChatGPT, pueden ofrecer una capacidad más avanzada para comprender el contexto y detectar defectos más sutiles.

Estudios han demostrado que GPT-4 tiene una precisión considerable en la detección de requisitos incompletos, aunque aún enfrenta desafíos al identificar ambigüedades e inconsistencias [12]. A pesar de estas limitaciones, se ha demostrado que los LLMs pueden reducir el esfuerzo humano en la validación de requisitos al automatizar parte del proceso.

En relación con la **PC1**, estos estudios muestran que ChatGPT puede asistir en actividades de creación y validación de requerimientos, particularmente mediante la automatización parcial del análisis. Respecto de la **PC4**, vinculada con la precisión de la información generada por ChatGPT, estudios reportan que GPT-4 presenta resultados favorables en la detección de incompletitud, aunque con limitaciones en otros tipos de defectos.

En línea con estos hallazgos, estudios experimentales recientes evidencian que el desempeño de GPT-4 varía según la naturaleza de la tarea analizada: el modelo presenta mayor precisión en tareas estructurales basadas en reglas explícitas que en aquellas que requieren interpretación semántica profunda o razonamiento contextual complejo [9]. Esta distinción resulta especialmente relevante para la ingeniería de requerimientos, donde muchos defectos se originan en ambigüedades conceptuales más que en errores formales. Asimismo, la evaluación de la precisión en sistemas basados en LLM enfrenta desafíos metodológicos, dado que las métricas automáticas tradicionales no capturan adecuadamente la corrección factual ni la adecuación contextual de las respuestas, particularmente en arquitecturas que combinan recuperación y generación [13]. A ello se suma que la integración de LLM en pipelines complejos puede introducir puntos críticos de fallo —como problemas de segmentación de documentos, ranking semántico deficiente y persistencia de alucinaciones— que afectan el desempeño en escenarios reales [13]. En conjunto, estos resultados muestran que la precisión observada en entornos controlados debe analizarse con cautela cuando los modelos se aplican en contextos prácticos de ingeniería de requerimientos.

En conjunto, los hallazgos de esta sección permiten abordar las **PC1** y **PC4**, vinculadas con el aporte y la precisión de ChatGPT en la ingeniería de requerimientos.

4. *Prompt Engineering* como Disciplina Emergente

A partir del análisis de los estudios incluidos en el mapeo sistemático, se observa que la calidad de las respuestas de los LLMs, como GPT-4, depende en gran medida de los *prompts*, o las instrucciones que se les proporcionan. En este contexto, la disciplina conocida como *Prompt Engineering* ha emergido para optimizar la interacción con estos modelos. *Prompt Engineering* involucra el diseño cuidadoso de las instrucciones que se proporcionan al modelo para maximizar la precisión, relevancia y utilidad de las respuestas generadas.

Los estudios revisados evidencian que el uso de técnicas de *Prompt Engineering* puede mejorar la precisión de los modelos en la *elicitación* de requisitos, particularmente mediante la incorporación de ejemplos específicos o contextos detallados en los *prompts*. Esto reduce la posibilidad de respuestas incorrectas o incompletas por parte de los LLMs.

En este sentido, investigaciones recientes proponen ir más allá de la simple redacción cuidadosa del *prompt*, incorporando lo que se denomina *structured requirement binding*, donde los requisitos se integran explícitamente dentro del *prompt* mediante identificadores formales, restricciones funcionales y contexto regulatorio. Este enfoque busca transformar el requisito en una restricción estructurada que guía la generación y mejora la alineación entre la salida del modelo y la intención original del artefacto [11]. De esta manera, el *Prompt Engineering* deja de ser únicamente una práctica heurística y comienza a consolidarse como una estrategia sistemática orientada a garantizar trazabilidad y consistencia en entornos asistidos por LLM.

4.1. Limitaciones en el Uso de Modelos LLM

En relación con la **PC2**, orientada a identificar los desafíos asociados al uso de *prompts*, los estudios analizados señalan que, a pesar del potencial de ChatGPT y otros modelos similares en la ingeniería de requisitos, existen limitaciones importantes que deben ser consideradas. Los LLMs, en su configuración estándar, no poseen conocimiento de dominio especializado y no siempre pueden manejar casos complejos que requieren una profunda comprensión técnica [12]. La incapacidad de los modelos para realizar razonamientos complejos sobre información técnica o para cruzar referencias dentro de un documento extenso sigue siendo un área de mejora clave.

Además, los modelos de lenguaje, en entornos *zero-shot*, pueden generar respuestas imprecisas si los *prompts* no son suficientemente detallados o claros. El uso de técnicas como *few-shot learning*, en las que se proporcionan ejemplos dentro del *prompt*, puede mejorar la precisión de las respuestas generadas por los LLMs.

Desde una perspectiva más amplia, también se ha observado que los problemas asociados al uso de *prompts* no se limitan únicamente a su redacción, sino que pueden estar vinculados a fallas estructurales en el pipeline de generación. En sistemas que combinan recuperación y generación, se han identificado puntos críticos como segmentación inadecuada de documentos, deficiencias en el ranking semántico y persistencia de alucinaciones incluso cuando se recupera información relevante [10]. Estos factores evidencian que la calidad de las respuestas no depende exclusivamente del *prompt* en sí, sino del diseño integral del sistema que soporta la interacción con el modelo, lo que complejiza aún más los desafíos asociados a la PC2.

En relación con la **PC2**, orientada a identificar los desafíos en el uso de *prompts*, los estudios analizados señalan que la falta de contexto y especificidad afecta directamente la calidad de las respuestas generadas. Estas limitaciones ponen de manifiesto que la efectividad de los LLMs en ingeniería de requerimientos depende en gran medida del diseño adecuado de los *prompts*, constituyendo uno de los principales desafíos identificados en el mapeo.

4.2. Impacto en la Práctica de la Ingeniería de Requisitos

Los estudios incluidos en el mapeo sistemático indican que el impacto del uso de ChatGPT y técnicas de *Prompt Engineering* en la práctica de la ingeniería de requisitos ha sido significativo. Estas herramientas no solo ayudan a automatizar la detección de defectos en los requisitos, sino que también tienen el potencial de acelerar la documentación y la verificación de requisitos. Sin embargo, la adopción completa de estas herramientas requiere una integración más fluida con las plataformas de gestión de requisitos tradicionales, como Jira, Trello o Confluence.

4.3. Herramientas y Frameworks que Integran IA Generativa

Desde una perspectiva aplicada, los estudios revisados describen diversas herramientas y *frameworks* [11] que comienzan a integrar IA generativa para apoyar la captura y gestión de requerimientos. GitHub *Copilot*, por ejemplo, utiliza modelos de lenguaje para sugerir código y documentación en tiempo real, lo que podría extenderse a la generación automática de especificaciones técnicas basadas en requisitos definidos en lenguaje natural. Otras herramientas, como Microsoft Azure DevOps, también están explorando la integración de IA para mejorar la colaboración y la documentación en el desarrollo de software.

En esta línea, propuestas recientes orientadas a la integración de LLM en entornos de desarrollo sugieren incorporar mecanismos de trazabilidad directamente dentro del flujo de generación,

incluyendo la inclusión automática de metadatos estructurados, identificadores de requisito y validación posterior mediante recuperación semántica [11]. Este enfoque permite no solo generar artefactos asistidos por IA, sino también mantener vínculos explícitos entre requisitos y salidas producidas por el modelo, facilitando su integración con herramientas tradicionales de gestión y control de versiones, y fortaleciendo la confiabilidad de la adopción práctica en contextos organizacionales.

En conjunto, los aspectos analizados en esta sección permiten dar respuesta a la **PC2**, vinculada con los desafíos del uso de *prompts*, y a la **PC3**, relacionada con las estrategias para mejorar la calidad de las respuestas generadas por los LLMs.

5. Desafíos y Beneficios del uso de ChatGPT en la Ingeniería de Requisitos

A partir de la síntesis de los estudios incluidos en el mapeo sistemático, se identifican una serie de beneficios y desafíos asociados al uso de ChatGPT en la ingeniería de requerimientos.

5.1. Beneficios

Mejora en la detección de defectos en requisitos

En relación con la **PC1**, orientada a analizar cómo ChatGPT puede asistir en la creación y análisis de requerimientos, los estudios revisados indican una mejora en la detección de defectos en requisitos. Los modelos de lenguaje como ChatGPT han demostrado ser útiles para detectar defectos comunes en los requisitos de software. En particular, pueden identificar ambigüedades cuando un requerimiento se puede interpretar de múltiples formas, lo que podría llevar a confusión durante la implementación. De manera similar, ChatGPT puede señalar inconsistencias cuando dos o más requisitos son contradictorios o incoherentes. Además, puede ayudar a detectar la incompletitud de los requisitos, es decir, cuando faltan detalles críticos, como rangos numéricos o especificaciones técnicas.

Capacidad para analizar grandes cantidades de documentación rápidamente

ChatGPT permite a los equipos de ingeniería de software procesar grandes volúmenes de requisitos de manera eficiente. En lugar de depender de revisiones manuales extensas, un modelo de IA puede realizar análisis rápidos y ofrecer sugerencias o correcciones inmediatas. Esto es especialmente útil en proyectos a gran escala, donde los requisitos a menudo abarcan cientos de páginas. Este beneficio refuerza el potencial de ChatGPT como herramienta de apoyo en actividades tempranas de la ingeniería de requerimientos, en línea con la **PC1**.

Apoyo en la automatización de tareas repetitivas

ChatGPT puede generar automáticamente secciones de documentos de requisitos basándose en ejemplos previos o especificaciones generales. Esto incluye la creación de plantillas para especificaciones de sistema, guías de usuario, o incluso la generación de escenarios de prueba. La automatización de estas tareas permite a los equipos concentrarse en tareas más complejas, como la toma de decisiones técnicas. La automatización de estas tareas constituye uno de los principales aportes identificados en la literatura analizada respecto del uso de ChatGPT en ingeniería de requerimientos (**PC1**).

Evidencia experimental reciente respalda estos beneficios al mostrar que modelos como GPT-4 pueden desempeñarse de manera consistente en tareas estructurales asociadas al análisis de artefactos

técnicos, alcanzando niveles elevados de corrección cuando se aplican reglas formales y patrones bien definidos [9]. Estos resultados sugieren que los LLM pueden actuar como asistentes eficaces en tareas de revisión preliminar, detección de omisiones estructurales y validación inicial de consistencia, reduciendo la carga cognitiva del ingeniero y acelerando ciclos tempranos de análisis de requisitos.

5.2. Desafíos

En relación con la **PC2**, centrada en los desafíos del uso de *prompts* para obtener información clara sobre los requerimientos, los estudios analizados destacan diversas limitaciones asociadas a los modelos de lenguaje.

Limitaciones de los modelos (falsos positivos, falta de entendimiento de dominio específico): A pesar de los avances, los modelos de lenguaje como ChatGPT no son infalibles [14]. Pueden generar falsos positivos, identificando defectos que en realidad no existen. Esto sucede porque carecen del conocimiento profundo de dominio necesario para comprender completamente los matices de ciertos requisitos técnicos. Los modelos tienden a basarse únicamente en patrones de lenguaje y no tienen una verdadera comprensión del contexto. Este aspecto pone de manifiesto que el diseño inadecuado de *prompts* constituye uno de los desafíos centrales identificados en el mapeo (**PC2**).

Dependencia de la calidad de los *prompts* (buen diseño de *prompts*): Los resultados que genera ChatGPT dependen en gran medida de la calidad de los *prompts* que se le proporcionan. Si los *prompts* son vagos o poco claros, las respuestas también lo serán. Esto introduce una nueva competencia en los equipos de ingeniería de software: la necesidad de diseñar *prompts* eficaces para obtener resultados útiles.

Falta de integración fluida en herramientas tradicionales de gestión de requisitos: Actualmente, muchas herramientas de gestión de requisitos no están diseñadas para integrarse fácilmente con modelos de lenguaje generativos como ChatGPT. Esto significa que los equipos deben trabajar en múltiples plataformas, lo que puede reducir la eficiencia y aumentar la posibilidad de errores. Esta limitación refuerza la necesidad de considerar la integración de los LLMs en el ecosistema de herramientas existentes, como uno de los desafíos recurrentes señalados en la literatura (**PC2**).

Estudios recientes han identificado múltiples puntos críticos en la ingeniería de sistemas basados en *Retrieval-Augmented Generation* (RAG). En particular, se describen fallos recurrentes como la ausencia de contenido relevante en la base de conocimiento, problemas en la segmentación de documentos (*chunking*), deficiencias en el ranking semántico y la persistencia de alucinaciones incluso cuando la información adecuada ha sido recuperada [13]. Asimismo, se ha evidenciado que la evolución de reglas de negocio y la actualización incompleta del conocimiento constituyen desafíos adicionales, ya que cuando la base histórica no refleja nuevas regulaciones el modelo puede generar respuestas incorrectas pese a que la arquitectura técnica funcione adecuadamente; además, la correcta contextualización depende de múltiples factores específicos que deben ser considerados explícitamente [15]. A ello se suma que la evaluación de la calidad en estas arquitecturas presenta dificultades metodológicas, dado que las métricas automáticas tradicionales no siempre capturan la adecuación contextual ni la corrección factual, lo que puede conducir a una sobreestimación de la confiabilidad del sistema [13]. En conjunto, estos hallazgos demuestran que la precisión en entornos de ingeniería de requerimientos no depende únicamente del modelo o del *prompt*, sino del diseño integral del *pipeline* de recuperación, actualización del conocimiento y validación humana.

En conjunto, los beneficios y desafíos identificados en esta sección permiten dar respuesta a la **PC1**, vinculada con el aporte de ChatGPT en la ingeniería de requerimientos, y a la **PC2**, relacionada con las dificultades y limitaciones en el uso de *prompts*.

6. Técnicas y Estrategias de *Prompt Engineering* para mejorar la Calidad de las Respuestas

En respuesta a la **PC3**, orientada a identificar cómo mejorar la calidad de las respuestas obtenidas mediante *prompts*, el análisis de los estudios incluidos en el mapeo sistemático propone diversas técnicas de *Prompt Engineering*. El *Prompt Engineering* juega un papel crucial en la optimización de las interacciones con modelos de lenguaje como ChatGPT. El diseño adecuado de un *prompt* (instrucción o consulta dada al modelo) puede marcar una gran diferencia en la calidad y relevancia de las respuestas generadas. Para garantizar que los resultados sean precisos y alineados con las necesidades de la ingeniería de requisitos, es esencial aplicar técnicas y estrategias efectivas al formular los *prompts* [10]. A continuación, se exploran algunos enfoques clave para mejorar la calidad de las respuestas generadas por modelos de lenguaje.

6.1. Tipos de *Prompts* Efectivos

Los estudios revisados coinciden en que los *prompts* efectivos son aquellos que son claros, específicos y ofrecen el contexto necesario para guiar al modelo hacia la respuesta deseada. Una de las características más importantes de estos *prompts* es la capacidad de eliminar la ambigüedad, asegurándose de que el modelo entienda claramente la tarea solicitada [16]. Existen varios tipos de *prompts* que pueden ser especialmente útiles en el contexto de la ingeniería de requisitos:

***Prompts* de Contexto Amplio:**

Estos *prompts* proporcionan al modelo un marco contextual más completo, lo que le permite generar respuestas más precisas y relevantes al tener en cuenta información adicional. Por ejemplo, al preguntar sobre un conjunto de requisitos, un *prompt* como "En este documento de requisitos, ¿hay alguna inconsistencia entre la sección de seguridad y la de autenticación?" permite que el modelo considere más elementos del contexto general del documento antes de ofrecer una respuesta.

***Prompts* Condicionales:**

Este tipo de *prompt* se utiliza cuando se desea que el modelo evalúe una condición específica antes de ofrecer una respuesta. Los *prompts* condicionales son útiles cuando se necesita una verificación basada en una acción o evento. Por ejemplo, un *prompt* como "Si el sistema no recibe una respuesta en 5 segundos, ¿qué debería ocurrir?" le permite al modelo procesar esa condición antes de sugerir un comportamiento o resultado.

***Prompts* de Verificación:**

Los *prompts* de verificación son particularmente útiles para asegurar que ciertos aspectos críticos estén presentes en un documento o conjunto de requisitos. Permiten confirmar que se han incluido todos los elementos necesarios. Un ejemplo de este tipo de *prompt* sería: "Confirma si todos los requisitos de accesibilidad están correctamente especificados en este documento.". Esto orienta al modelo a buscar y confirmar la presencia de elementos clave en el texto.

En el contexto de la ingeniería de requisitos, la claridad, especificidad y amplitud de los *prompts* resultan esenciales para obtener resultados que realmente aporten valor. Estos enfoques permiten que

el modelo se concentre en las áreas más relevantes del texto y reduzcan el riesgo de generar respuestas ambiguas o incompletas [12].

Más allá de la claridad y especificidad textual, investigaciones recientes proponen estructurar los prompts incorporando identificadores formales de requisitos, restricciones explícitas y metadatos de trazabilidad, con el objetivo de guiar la generación de manera más controlada. Este enfoque, denominado *structured requirement binding*, integra dentro del *prompt* referencias directas a requisitos específicos (por ejemplo, mediante etiquetas estructuradas) y establece restricciones declarativas que reducen la variabilidad de salida y mejoran la alineación semántica entre el requisito y el artefacto generado [11]. De este modo, el *Prompt Engineering* evoluciona desde una práctica basada en heurísticas lingüísticas hacia una estrategia más sistemática orientada a garantizar consistencia, auditabilidad y estabilidad en entornos de ingeniería de requerimientos.

Estos tipos de *prompts* representan estrategias recurrentes identificadas en la literatura analizada para mejorar la calidad de las respuestas generadas por los LLMs (**PC3**).

6.2. Estrategias de Few-shot y Zero-shot

Dentro del conjunto de técnicas relevadas en el mapeo sistemático, se destacan dos estrategias comunes de *Prompt Engineering* para interactuar con modelos de lenguaje: *few-shot* y *zero-shot*. Estas estrategias permiten optimizar el rendimiento del modelo según el contexto y la información disponible:

Estrategia Zero-shot:

En la estrategia *zero-shot*, se le pide al modelo que realice una tarea sin haber recibido ejemplos específicos con anterioridad. Esto es útil cuando el modelo ya cuenta con un conocimiento suficientemente amplio del dominio o cuando se busca una interpretación general de los requisitos. En este caso, la calidad del *prompt* es clave, ya que no se le proporcionan ejemplos adicionales para contextualizar la tarea. Por ejemplo, un *prompt* del tipo "Detecta inconsistencias en este conjunto de requisitos" es una tarea *zero-shot* donde el modelo deberá interpretar la tarea sin ejemplos previos.

Estrategia Few-shot:

En contraste, la estrategia *few-shot* consiste en proporcionar uno o más ejemplos específicos que guíen al modelo en la tarea que debe realizar. Esto puede ser particularmente útil en situaciones más complejas o técnicas, donde el modelo puede beneficiarse de ejemplos que aclaren el formato o la lógica requerida para su respuesta. Por ejemplo, al analizar requisitos de seguridad, se pueden incluir ejemplos que muestren cómo deben formularse esos requisitos antes de pedirle al modelo que genere más. Esta estrategia mejora significativamente la precisión, especialmente cuando se trata de tareas complejas o contextos técnicos específicos.

Ambas estrategias permiten adaptar el modelo según el grado de especificidad o generalidad que se requiere en las respuestas, lo que mejora la efectividad en la generación de información relevante.

Evidencia experimental reciente respalda la utilidad de estas estrategias al demostrar que la incorporación de estructuras adicionales en el *prompt*, como reglas explícitas o razonamiento paso a paso, puede mejorar el desempeño del modelo en tareas formales. En evaluaciones controladas, el uso de enfoques estructurados permitió a GPT-4 alcanzar mayores niveles de corrección en comparación con configuraciones más simples, especialmente en tareas basadas en reglas definidas [9]. Estos resultados sugieren que la estrategia *few-shot*, combinada con indicaciones

estructuradas, resulta particularmente efectiva cuando la tarea requiere precisión técnica o cumplimiento de patrones específicos.

La comparación entre estrategias *few-shot* y *zero-shot* permite identificar patrones de mejora en la precisión y relevancia de las respuestas, constituyendo un aporte directo a la **PC3**.

6.3. Consideraciones Técnicas en el Diseño de Prompts

A partir de la síntesis de los estudios analizados, se identifican diversos factores técnicos que influyen en la calidad de los *prompts* y, en consecuencia, en las respuestas generadas por los modelos de lenguaje. Algunas de las consideraciones más importantes incluyen:

Longitud del Prompt:

Los prompts más largos tienden a proporcionar más contexto al modelo, lo que generalmente conduce a respuestas más detalladas y precisas. Sin embargo, es crucial equilibrar la cantidad de información proporcionada para evitar abrumar al modelo con detalles innecesarios. Por ejemplo, en el caso de requerimientos complejos, es preferible estructurar el *prompt* de manera que proporcione el contexto suficiente sin incluir información redundante.

Especificidad del Lenguaje:

El uso de un lenguaje técnico claro y preciso es fundamental para mejorar la exactitud de las respuestas. En la ingeniería de requisitos, términos vagos o ambigüedades en el lenguaje pueden llevar a respuestas incorrectas o irrelevantes. Un prompt específico que use términos técnicos claros permite que el modelo comprenda mejor la tarea y produzca una salida más alineada con las expectativas.

Formato Estructurado:

La manera en que se estructura un *prompt* puede influir en cómo el modelo procesa la información. Formular preguntas de manera lógica, o utilizar listas numeradas, ayuda al modelo a interpretar mejor la tarea solicitada. Por ejemplo, al solicitar que el modelo evalúe diferentes secciones de un documento de requisitos, un *prompt* estructurado en secciones o pasos específicos facilita la comprensión y mejora la precisión en las respuestas.

Además de estos factores, estudios recientes destacan que la estabilidad de las respuestas puede verse afectada por la naturaleza estocástica del modelo, incluso cuando el *prompt* se mantiene constante. Se ha observado que la generación puede variar entre ejecuciones sucesivas, lo que introduce desafíos en términos de reproducibilidad y consistencia en entornos críticos [17]. En este contexto, se recomienda complementar el diseño estructurado del *prompt* con mecanismos de control, como la inclusión de restricciones explícitas y metadatos de trazabilidad, para reducir la variabilidad y mejorar la alineación entre requisito y salida generada.

Estas consideraciones técnicas sintetizan los principales factores identificados en la literatura para optimizar el diseño de prompts en contextos de ingeniería de requerimientos (**PC3**).

6.4. Evaluación del Impacto del Prompt Engineering en la Calidad de los Textos Generados

Los estudios incluidos en el mapeo sistemático destacan la importancia de evaluar la efectividad del *Prompt Engineering* mediante criterios claros que permitan analizar el rendimiento del modelo en términos de precisión, relevancia y coherencia [16]. Algunas métricas clave incluyen:

Precisión:

Este criterio evalúa cuántas de las respuestas generadas por el modelo son correctas en comparación con los estándares o expectativas predefinidas. En el contexto de la ingeniería de requisitos, la precisión se refiere a la capacidad del modelo para identificar y resolver defectos en los requisitos, como ambigüedades o inconsistencias.

Relevancia:

La relevancia mide si las respuestas del modelo abordan específicamente las necesidades planteadas en el *prompt*. Un modelo que ofrece respuestas relevantes es capaz de concentrarse en las áreas más importantes del texto o de la tarea, evitando respuestas fuera de contexto.

Calidad Lingüística:

Es importante también evaluar la calidad lingüística de las respuestas generadas. Esto incluye verificar que las respuestas sean claras, libres de errores y adecuadas para su uso en un contexto práctico. La coherencia gramatical y la estructura lógica de las respuestas son aspectos cruciales que determinan la calidad general de los textos generados.

Realizar experimentos que comparen los resultados obtenidos mediante diferentes estrategias de *prompting* puede ayudar a identificar cuáles son más efectivas [18,19] en diferentes contextos. Variaciones en el diseño de los *prompts*, como el uso de ejemplos en estrategias *few-shot* o la incorporación de más contexto en *prompts* largos, pueden afectar significativamente la calidad de las respuestas y proporcionar información valiosa sobre cómo mejorar el rendimiento del modelo.

En conjunto, las técnicas y estrategias analizadas en esta sección permiten dar respuesta a la **PC3**, evidenciando cómo el diseño adecuado de *prompts* contribuye a mejorar la calidad y precisión de las respuestas generadas por los LLMs en la ingeniería de requerimientos. No obstante, investigaciones recientes advierten que la evaluación de sistemas basados en generación aumentada por recuperación presenta limitaciones cuando se utilizan únicamente métricas automáticas tradicionales, dado que estas no siempre capturan la corrección factual ni la adecuación contextual de las respuestas [13]. En consecuencia, se propone complementar las métricas cuantitativas con evaluación humana experta y análisis cualitativo, especialmente en dominios técnicos como la ingeniería de requerimientos, donde la validez semántica y la coherencia con el dominio son factores críticos.

7. Conclusión

A partir del mapeo sistemático realizado, los resultados obtenidos indican que el uso de ChatGPT y técnicas de *Prompt Engineering* en la ingeniería de requerimientos puede mejorar significativamente la detección de defectos y la generación de documentación. Pero a pesar de su potencial, los LLM pueden introducir sesgos o perpetuar errores derivados de los datos con los que fueron entrenados, lo que requiere una supervisión cuidadosa durante el proceso de ingeniería de requisitos.

En relación con las Preguntas Clave planteadas, los hallazgos del mapeo permiten sintetizar los principales aportes, desafíos y limitaciones del uso de ChatGPT en la ingeniería de requerimientos. En este sentido, los resultados permiten dar respuesta a la **PC1**, evidenciando el potencial de ChatGPT como herramienta de apoyo en la creación, análisis y validación de requerimientos; a la **PC2**, identificando los principales desafíos asociados al diseño de *prompts*; y a la **PC3**, destacando técnicas y estrategias de *Prompt Engineering* orientadas a mejorar la calidad de las respuestas generadas.

Asimismo, los estudios analizados permiten abordar la **PC4**, mostrando que, si bien los modelos como GPT-4 presentan niveles de precisión adecuados en determinadas tareas, aún exhiben limitaciones en la detección de ambigüedades e inconsistencias complejas.

En conjunto, este mapeo sistemático ofrece una visión estructurada del estado actual de la investigación sobre el uso de LLMs y *Prompt Engineering* en la ingeniería de requerimientos, aportando una base para futuras investigaciones y aplicaciones prácticas en el área.

Referencias

- [1] T. Mahbub, D. Dghaym, A. Shankarnarayanan, T. Syed, S. Shapsough and I. Zualkernan, "Can GPT-4 aid in detecting ambiguities, inconsistencies, and incompleteness in requirements analysis? A comprehensive case study," in IEEE Access, doi: 10.1109/ACCESS.2024.3464242.
- [2] Marques, N., Silva, R. R., & Bernardino, J. (2024). Using ChatGPT in Software Requirements Engineering: A Comprehensive Review. *Future Internet*, 16(6), 180. <https://doi.org/10.3390/fi16060180>
- [3] Marr, B. A Short History of ChatGPT: How We Got to Where We Are Today. Available online: <https://www.forbes.com/sites/bernardmarr/2023/05/19/a-short-history-of-chatgpt-how-we-got-to-where-we-are-today/?sh=454c1d75674f> (accessed on 1 March 2024).
- [4] Sommerville, I., & Sawyer, P. (1997). *Requirements engineering: a good practice guide*. John Wiley & Sons, Inc.
- [5] P. Liu, W. Yuan, J. Fu, Z. Jiang, H. Hayashi, and G. Neubig, "Pre-train, prompt, and predict: A systematic survey of prompting methods in natural language processing," *ACM Computing Surveys*, vol. 55, no. 9, pp. 1–35, 2023.
- [6] Arvidsson, S. (2023). *Prompt engineering guidelines for LLMs in Requirements Engineering*. University of Gothenburg/Department of Computer Science and Engineering.
- [7] J. White, Q. Fu, S. Hays, et al., "A prompt pattern catalog to enhance prompt engineering with chatgpt," *arXiv preprint arXiv:2302.11382*, 2023.
- [8] Guido Tebes, Denis Peppino, Pablo Becker y Luis Olsina, "Proceso para Revisión Sistemática de Literatura y Mapeo Sistemático".
- [9] Kimya Khakzad Shahandashti, Mithila Sivakumar, Mohammad Mahdi Mohajer, Alvine Boaye Belle, Song Wang, and Timothy Lethbridge. 2024. Assessing the Impact of GPT-4 Turbo in Generating Defeaters for Assurance Cases. In *Proceedings of the 2024 IEEE/ACM First International Conference on AI Foundation Models and Software Engineering (FORGE '24)*. Association for Computing Machinery, New York, NY, USA, 52–56. <https://doi.org/10.1145/3650105.3652291>
- [10] Scott Barnett, Stefanus Kurniawan, Srikanth Thudumu, Zach Brannelly, and Mohamed Abdelrazek. 2024. Seven Failure Points When Engineering a Retrieval Augmented Generation System. In *Proceedings of the IEEE/ACM 3rd International Conference on AI Engineering - Software Engineering for AI (CAIN '24)*. Association for Computing Machinery, New York, NY, USA, 194–199. <https://doi.org/10.1145/3644815.3644945>
- [11] Fei Wang, XueFeng Xi, ZhiMing Cui, Huan Dai, and XinYu Wang. 2025. Embedding Traceability in Large Language Model Code Generation: Towards Trustworthy AI-Augmented Software Engineering. In *Proceedings of the 33rd ACM International Conference on the Foundations of Software Engineering (FSE Companion '25)*. Association for Computing Machinery, New York, NY, USA, 1760–1763. <https://doi.org/10.1145/3696630.3730569>.
- [12] Frank P.-W. Lo, Jianing Qiu, Zeyu Wang, Junhong Chen, Bo Xiao, Wu Yuan, Senior Member, IEEE, Stamatia Giannarou, Gary Frost and Benny Lo, Senior Member, IEEE, "Dietary Assessment with Multimodal ChatGPT: A Systematic Analysis". Acceso desde IEEE Xplore 10.1109/JBHI.2024.3417280:
- [13] Souvick Das, Novarun Deb, Nabendu Chaki, and Agostino Cortesi. 2025. A Multi-Agent RAG Framework for Regulatory Compliance Checking of Software Requirements. *ACM Trans. Softw. Eng. Methodol.* Just Accepted (December 2025). <https://doi.org/10.1145/3785472>
- [14] Denis Donadel, Francesco Marchiori, Luca Pajola, Mauro Conti, Spritz Matter Srl;. Can LLMs Understand Computer Networks? Towards a Virtual System Administrator", revisado en IEEE Xplore, DOI: 10.1109/LCN60385.2024.10639641.

- [15] Tor Sporseem and Rasmus Ulfesnes. 2025. Towards Requirements Engineering for RAG Systems. In Proceedings of the 29th International Conference on Evaluation and Assessment in Software Engineering (EASE '25). Association for Computing Machinery, New York, NY, USA, 782–788. <https://doi.org/10.1145/3756681.3757040>
- [16] C. Arora, J. Grundy, and M. Abdelrazek, “Advancing requirements engineering through generative ai: Assessing the role of llms,” arXiv preprint arXiv:2310.13976, 2023.
- [17] Jiawei Shao, Jingwen Tong, Qiong Wu, Wei Guo, Zijian Li, Zehong Lin, Jun Zhang. “WirelessLLM: Empowering Large Language Models Towards Wireless Intelligence”. Acceso desde IEEE Xplore, DOI: 10.23919/JCIN.2024.10582827
- [18] Daeseung Park¹, Gi-taek An², Chayapol Kamyod³, and Cheong Ghil Kim^{1,*} “A Study on Performance Improvement of Prompt Engineering for Generative AI with a Large Language Model” Consultado en IEEE Xplore,, DOI: 10.13052/jwe1540-9589.2285.
- [19] Toufique Ahmed, Kunal Suresh Pai, Premkumar Devanbu, Earl T. Barr, “Automatic Semantic Augmentation of Language Model Prompts (for Code Summarization)”. 2024 IEEE/ACM 46th International Conference on Software Engineering (ICSE), revisado en IEEE Xplore: <https://ieeexplore.ieee.org/document/10548617>

Caracterización de Muros EPS – MC y Comparativas con Casos Convencionales

Javier A. Duarte^{1,*} , Alicia E. Ares² , Oscar Möller³ , Néstor H. Neudeck¹ , María B. Statkiewicz¹ 

¹ Universidad Nacional de Misiones. Facultad de Ingeniería. Departamento de Ingeniería Civil. Laboratorio de Ingeniería Civil (LIC). Oberá, Misiones, Argentina.

² IMAM, UNaM, CONICET, FCEQyN, Félix de Azara 1552, N3300LQD, Misiones, Argentina.

³ Universidad Nacional de Rosario. Consejo de Investigaciones (CIUNR), Instituto de Mecánica Aplicada y Estructuras (IMAE). Riobamba y Berutti 2000, Rosario, Argentina.

e-mails: javier.duarte@fio.unam.edu.ar, aares@fceqyn.unam.edu.ar, moller@fceia.unr.edu.ar, neudeck@fio.unam.edu.ar, maribelstat@gmail.com

Resumen

En la provincia de Misiones, la demanda de construcción de viviendas es una temática de constante análisis en los ámbitos público y privado, promoviendo el análisis de soluciones innovadoras en los sistemas constructivos a efectos de fijar criterios de seguridad y economía, así como el estudio de alternativas de procedencia local. La información disponible de dichos sistemas alternativos en la región de Misiones genera la necesidad de estudiar las propiedades de nuevos materiales para mamposterías, dando lugar a ampliar opciones de solución desde el medio profesional a diferentes situaciones de diseño constructivo habitacional. Por otra parte, es importante sobre la base de estudios previos efectuar avances y actualizaciones de dichas soluciones, aportando de manera gradual, la mitigación de los efectos ambientales que produce la fabricación de materiales de construcción, como es el caso del cemento y el acero. El objetivo de este trabajo es la obtención de parámetros de resistencia de ladrillos de poliestireno expandido rellenos con mortero de cemento (CLEPS) mediante ensayos experimentales de rotura a compresión y luego realizar una comparación con sistemas convencionales de ladrillo cerámico hueco (CLCH) con diferentes tipos de morteros de unión. Se espera que los resultados de esta investigación aporten, en trabajos futuros, fundamentos adecuados para el desarrollo de alternativas que mejoren la relación costo-beneficio de los sistemas constructivos regionales, como también amplíe el espectro de investigación de dichos sistemas.

Palabras clave – Mampostería, Ladrillo, Sistemas alternativos, Cerámica, Poliestireno expandido.

Abstract

In the province of Misiones, the demand for housing construction is subject of constant analysis in public and private sectors, promoting the analysis of innovative solutions in construction systems in order to establish safety and economic criteria, as well as the study of locally sourced alternatives. The information available on alternative systems in the Misiones region generates the need to study the properties of new materials for masonry, giving rise to expanding solution options from the professional level to different housing construction design situations. Furthermore, it is important, based on previous studies, to make advances and updates of solutions, gradually contributing to the mitigation of environmental effects that produce the manufacture of construction materials, as is the case of cement and steel. The objective of this research is to obtain resistance parameters of expanded polystyrene bricks filled with cement mortar through experimental compression rupture tests, and then to carry out a comparison with conventional, hollow ceramic brick systems using different types of bonding mortars. It is expected that the results of this investigation will provide future studies with adequate foundations for the development of alternatives that improve the cost-benefit relationship of regional construction systems, as well as broaden the research spectrum of these systems.

Keywords – Masonry, brick, alternative systems, ceramic, Expanded Polystyrene.

1. Introducción

La provincia de Misiones ha presentado en las últimas décadas un marcado déficit en términos de cobertura de la demanda habitacional, magnificado por el considerable crecimiento demográfico de las zonas urbanas. Esto tiene como efecto colateral un impacto en la economía circular, el cual cuenta con varios matices.

Analizado en términos de porcentaje de incidencia del costo total de obra en [1], las mamposterías conforman el bloque de obra húmeda y representan para el caso de viviendas un 18 a 28% (para edificios el orden es del 12% a 15%), lo cual justifica analizar técnicas que permitan optimizar su costo. Además, en [1] se verificó la hipótesis de una reducción significativa en el costo de una estructura cuando se aprovechan los muros de cerramiento, logrando así disminuir secciones tanto de hormigón como de acero (elementos de la estructura resistente) que inciden de forma considerable en el costo de obras civiles.

La mampostería, como cerramiento utilizado en viviendas, desempeña un papel importante en la estabilidad y resistencia estructural de los edificios, según lo especificado en [12]. Desde dicho enfoque, es esencial comprender los parámetros que afectan su desempeño mecánico dentro del sistema global de la estructura resistente (ver [10]). Entre estas medidas, la resistencia a compresión es un parámetro mecánico válido para determinar la calidad del material utilizado en el muro, sin dejar de lado los modos de falla que según [2] son, a saber: fractura del ladrillo, falla mecánica del mortero de junta y/o deslizamiento de estos en la interfaz mortero-mampuesto. Estas propiedades se amplifican cuando se logra administrar una presión de confinamiento con elementos de hormigón según [9].

En [4] se concluyen comparaciones en la región de Valdivia, Chile, sobre prototipos de viviendas construidas con bloques EPS en donde se utilizan hormigones como relleno. Entre otros aspectos, deja como aspecto positivo la factibilidad técnica de que este material es compatible con un circuito de economía circular.

En las conclusiones de [5], se establecen comentarios positivos respecto al uso de sistemas de cerramiento basados en piezas de EPS, recomendando se refuercen las mismas con perfiles metálicos para anclaje de elementos, a la vez que se recomienda no usar este sistema en paredes interiores. Esto último, condicionado a la posibilidad de revestir el mencionado cerramiento exterior con morteros cementicios.

El poliestireno expandido (EPS), como alternativa en la construcción de mamposterías, presenta características distintas que lo diferencian de los demás ladrillos convencionales, como sea su deformabilidad, propiedad aislante y acústica. Este es capaz de soportar ciertas deformaciones, pero su función principal es dar confort térmico y acústico a partir de ser utilizado como cerramiento.

En el prototipo analizado en el presente trabajo, su interior se rellena en dos orificios de 50 mm con una mezcla elaborada con cemento y arena en cantidades usuales para el ámbito de la construcción, con propiedades de adhesión y resistencia mecánica adecuadas, para garantizar una unión y encastre entre los ladrillos de poliestireno expandido.

Dicha adhesión entre mampuestos se obtiene mediante una junta de mortero elaborada con adhesivo para cerámicas de uso frecuente en el mercado, disponible en bolsas cerradas de 25 kg con el material listo para mezclar con agua. La relación agua-mortero se mide por consistencia hasta obtener una mezcla de consistencia estable que al contacto con la cuchara de albañil no derrame por gravedad.

En [13] se destaca el uso de EPS como adición para fabricar ladrillos livianos para mampostería utilizando como materia prima caolín y EPS, mediante un proceso de sinterización a 1200 °C. En este trabajo se analizaron muestras con diferente porcentaje de EPS en la mezcla, logrando diferencias tanto en el tamaño de la microestructura como en los valores de resistencia de los mampuestos.

En [14], Se realizaron ensayos de bloques con diferente dosificación, de los cuales el cuarto ensayo fue óptimo para bloques alivianados con una dosificación de 20% de poliestireno expandido, PET, vermiculita. Además, se obtuvieron valores de resistencia a compresión y se realizaron análisis de impacto económico y ambiental del producto.

El objetivo de este trabajo es la obtención de parámetros mecánicos de ladrillos cerámicos y de poliestireno expandido con núcleo de mortero de cemento mediante ensayos experimentales de rotura a compresión, a efectos de evaluar en una comparativa su resistencia respecto de los resultados obtenidos en [12], el cual mostró datos de resistencia a compresión en celdas ejecutadas con mortero convencional. Para este trabajo se realizó una segunda tanda construida con juntas de adhesivo para cerámicas.

El presente trabajo se basó en comparar resultados entre celdas EPS y celdas LCH de primera y segunda tanda. Los resultados se presentaron en tablas separadas y se obtuvieron parámetros estadísticos de cada lote de celdas. Los datos del presente documento corresponden a celdas de EPS y a celdas de LCH de segunda tanda, los cuales se realizaron siguiendo el mismo protocolo de ensayo a rotura hasta obtener la resistencia a compresión.

La experiencia se realizó en el Laboratorio de Ingeniería Civil de la Facultad de Ingeniería de la Universidad Nacional de Misiones, en donde se realizaron ensayos de probetas “Celda” de mamposterías (término utilizado para describir una probeta conformada con ladrillos unidos con mortero de junta simulando la trabazón usual que siguen dentro del esquema de replanteo de un muro de cerramiento).

Se espera que la presente investigación brinde comparativas concretas entre resultados de ensayos idénticos en los diferentes prototipos analizados a efectos de establecer criterios de diseño en diferentes opciones de cerramientos que permiten reducir el consumo de cemento y otros materiales de costo significativo y con efectos colaterales en su fabricación como las emisiones de CO₂ y otros gases de efecto invernadero.

2. Metodología

Los ladrillos EPS utilizados en el presente trabajo, son de fabricación local impulsada por un profesional de la zona. El proceso de fabricación posee tecnología basada en procesos electromagnéticos preservados por el fabricante, dando como resultado un bloque de perlas de EPS maniobrable y estable para ser utilizado en cerramientos.

Para obtener datos geométricos de las piezas a ensayar se registraron las dimensiones de cada elemento a usar y una designación codificada (*LT-Lote-Unidad*). La Fig. 1 muestra un esquema de los parámetros geométricos a registrar para el análisis experimental. Se tomaron cuatro medidas de largo (L1), de ancho (L2) y de alto (H), además de los diámetros en ambas caras (D1 y D2) para luego analizar sus medidas estadísticas.




Fig. 1. Parámetros definidos para el protocolo de caracterización geométrica.

Las probetas se trataron combinando dos materiales de propiedades mecánicas diferentes. Se emplearon ladrillos conformados de poliestireno expandido (EPS), los cuales contaban con dos orificios centrados de manera simétrica que recorren la altura del ladrillo. Estos orificios se completaron con mortero MC 1:3 dosificado en relación P/P con el objetivo de evaluar el aporte de rigidez del mortero al nuevo elemento compuesto (MC 1:3 + EPS).

La Fig. 2 muestra una imagen de las probetas preparadas para iniciar el proceso de fragüe. En este punto se hace una división del total de los ladrillos, para preparar los ensayos individuales (fig. 3) y celdas (fig. 4), que están compuestas por 3 ladrillos de EPS, que simularán el comportamiento en conjunto de estos. Los ladrillos fueron codificados con la sigla LT y numerados de tal forma de poder establecer la trazabilidad en los procesos de caracterización geométrica.

Se realiza un encabezado con una mezcla de yeso/cemento (50/50) para darle cierta rigidez al momento de distribuir la carga sobre estos, tanto sobre los ladrillos que se van a ensayar de manera individual como las celdas una vez armadas.

Para los ensayos de compresión de las celdas, se siguió el procedimiento establecido por IRAM 12737, adaptado a las particularidades del material compuesto con algunos ajustes de forma. Desde este enfoque se elaboraron probetas en donde se dispusieron juntas horizontales y verticales para evaluar características y trayectorias de las eventuales fallas que pudiera sufrir cada espécimen. Para otros casos convencionales, los modos de falla se ubican en el ladrillo, en el mortero de junta y en la interfaz entre junta y ladrillo.



Fig. 2. EPS relleno con mortero de cemento 1:3.



Fig. 3. Ladrillos individuales de EPS.



Fig. 4. Ladrillos en formato celdas de EPS unidos con adhesivo para cerámicas.

Las Figs. 5 y 6 muestran las características de las celdas elaboradas para ensayos de resistencia a compresión. La diferencia en el uso de mortero para unir cada ladrillo dio como resultado una diferencia mínima en el tamaño de la probeta.



Fig. 5. Celdas de LCH unidos con adhesivo para cerámicas – CLCH-AC.



Fig. 6. Celdas de LCH unidos con mortero de cemento de albañilería – CLCH-CA.

Se realizaron ensayos a compresión para las celdas de CLEPS y celdas de CLCH en dos tandas aplicando el protocolo descrito en [8], para los ladrillos individuales LEPS y LCH se aplicó el protocolo [4]. Además, se ensayaron probetas de mortero aplicando la norma IRAM 1622, donde este mortero utilizado para rellenar un doble núcleo circular de LEPS. Ante la ausencia de normas específicas para materiales de estas características se adoptó el criterio de adaptar el marco referente a mamposterías de ladrillo macizo y ladrillos cerámicos huecos (LCH).

Los ensayos realizados en probetas LCH y EPS siguieron el mismo protocolo, midiendo en cada experimento, la carga aplicada mediante una placa rígida de acero que desciende a través de un dispositivo denominado “Jaula de ensayo”, el cual permite guiar la aplicación de la carga en perfecta verticalidad. Además, se midió el desplazamiento vertical en cada esquina de la placa de asiento que sirve de transición entre el pistón de la prensa, la celda de carga y la probeta ensayada.

La Fig. 7 muestra la jaula de ensayo utilizada en un ensayo de celdas LCH realizado en el Laboratorio de Ingeniería Civil (LIC) de la Facultad de Ingeniería (FI) de la Universidad Nacional de Misiones (UNaM).

Para los ensayos de rotura correspondientes a ladrillos individuales y probetas de morteros se utilizó una prensa marca COSACOV de capacidad nominal máxima de 50 KN, por otro lado, se utilizó una prensa hidráulica IBERTEST con capacidad nominal de 1500 KN para los ensayos de celdas de mampostería.

Respecto del instrumental de medición, se utilizaron una celda de carga de 50 KN en el caso de la primera prensa y un adquisidor de datos con frecuencia de muestreo de 5 Hz, mientras que para la segunda prensa se utilizó una celda de carga de 1000 KN incorporada de manera fija al equipo.

Para medir desplazamientos (acortamientos de probetas) se utilizaron extensómetros conectados al sistema de adquisición de datos, provistos de una precisión del orden de centésimas de mm. Se dispusieron en cada esquina de la placa de asiento de carga y se tomó el desplazamiento promedio para realizar las estimaciones de deformación específica.

La Fig. 8 muestra el equipo de adquisición de señales desarrollado por el Laboratorio de Simulación y Ensayos mecánicos de la Universidad Nacional de Misiones.




Fig. 7. Jaula de ensayo para celdas de mampostería.




Fig. 8. Dispositivos de adquisición de datos.

La Fig. 9 muestra imágenes de los dispositivos utilizados para ensayar las muestras de mortero, ladrillos rellenos con mortero y celdas de ladrillos rellenas con mortero.



a) b)
Fig. 9. Dispositivos de ensayo: a) a tracción por flexión; b) a compresión.

3. Resultados

Para los resultados obtenidos en el caso de ladrillos LCH, se puede ver en la referencia [2] que los valores de resistencia a compresión estuvieron en un orden de casi 9 MPa con un desvío del 13%, mientras que, para la resistencia a Flexión, se obtuvo un promedio de 0,80 MPa con un desvío del orden de 8%. En cuanto a los valores obtenidos en celdas de mampostería LCH, se obtuvo un promedio de 4,66 MPa con un desvío de 6,88%. Dichos valores se contrastaron con modelos de resistencia propuestos por Oller (2014).

La Fig. 10 muestra fallas ocurridas en el ensayo ejecutado en CLEPS, donde se registraron roturas por tracción perpendicular a la línea de aplicación de la carga y con respecto al valor de resistencia se consideró atribuido al núcleo elaborado con mortero de cemento.



Fig. 10. Modos de falla observados en celdas de ladrillos EPS unidos con adhesivo para cerámicas.

La Fig. 11 muestra fallas ocurridas en el ensayo ejecutado en CLCH-CA, donde se registraron fallas en el ladrillo y en el mortero de unión, siendo estas predominantes. Se pudo observar además que las fallas en el mortero produjeron diversas fallas locales en la estructura interna del ladrillo.



Fig. 11. Modos de Falla en celdas CLCH-CA.

La Fig. 12 muestra las fallas registradas en ensayos de celdas CLCH-AC, en donde se puede observar la predominancia de las fallas en el ladrillo y en la interfaz entre mortero y ladrillo, por diferentes efectos combinados entre compresión, tracción, corte y flexión.



Fig. 12. Modos de falla en celdas CLCH-AC.

La Tabla 1 presenta los resultados del procesamiento estadístico, con indicadores de dispersión, asimetría y curtosis correspondientes a las dimensiones geométricas de ladrillos EPS utilizados para estas experiencias. Las dimensiones de cada ladrillo se obtuvieron con calibre digital de precisión de 0.01 mm y se relevaron dimensiones globales exteriores y diámetros interiores de orificios verticales. Los parámetros estadísticos y sus expresiones aritméticas se muestran a continuación en las ecuaciones (1) a (5):

$$\bar{x} = \frac{\sum x_i}{n} \quad \bar{x}: \text{valormedio} \quad (1)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}}, \sigma: \text{desvió típico} \quad (2)$$

$$CV = \frac{\sigma}{\bar{x}}, CV: \text{Coeficiente de Variación} \quad (3)$$

$$CA = \frac{n \sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)(n-2)\sigma^3}, CA: \text{Coeficiente de Asimetría} \quad (4)$$

$$CC = \frac{n(n+1) \sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)(n-2)(n-3)\sigma^4} - \frac{3(n-1)^2}{(n-2)(n-3)}, C: \text{Coeficiente de Curtosis} \quad (5)$$

Luego se evaluó la resistencia mecánica a compresión y tracción por flexión en diferentes formatos: ladrillos individuales, celdas de ladrillos con trabas, juntas horizontales y verticales, y probetas normalizadas de mortero de cemento. Los formatos analizados en el presente artículo fueron celdas de ladrillos EPS (CLEPS), celdas de ladrillos cerámicos huecos unidos con mortero de cemento de albañilería (CLCH-CA) y celdas de ladrillos cerámicos huecos unidos con adhesivo para cerámica (CLCH-AC).

Tabla 1. Resumen estadístico de caracterización geométrica de ladrillos EPS.

Parámetros estadísticos	L1 [mm]	L2 [mm]	H [mm]	D1 ^{sup} [mm]	D2 ^{sup} [mm]	D1 ^{inf} [mm]	D2 ^{inf} [mm]
Media	248,03	119,3	120,7	48,4	48,4	44,3	44,4
Desvío típico	0,132	0,043	0,060	0,226	0,227	0,163	0,174
Variación %	0,53 %	0,36 %	0,50 %	4,68 %	4,68 %	3,67 %	3,92 %
Asimetría	0,001	-0,40	-1,31	-2,26	-2,15	1,94	2,07
Curtosis	-0,98	0,69	2,18	3,76	3,39	3,27	3,14

La caracterización mecánica de CLEPS se realizó sobre un total de 14 probetas de ladrillos individuales, 14 celdas, 15 probetas de mortero a flexión y 30 probetas de mortero a compresión. Para los experimentos realizados en CLCH-CA y CLCH-AC se utilizaron 18 probetas de cada especie en turnos experimentales diferentes.

Se observa que, para los ensayos de compresión de 1 a las celdas de ladrillos, los resultados se presentan en la tabla 2, en la cual se observan la media, el desvío típico, el coeficiente de variación y medidas de distribución y asimetría.

Los parámetros analizados indican la carga máxima en cada ensayo y su acortamiento correspondiente; luego se calcularon la resistencia y la deformación específica para proceder a la estimación del módulo elástico a compresión en ambos casos. En todos los ensayos se registró la velocidad de carga para confirmar el carácter monótonico de las pruebas mecánicas.

La tabla 3 muestra los resultados de ensayos efectuados en ladrillos individuales LEPS, en donde se registraron la carga de rotura, acortamiento, resistencia a compresión y deformación específica.

La tabla 4 muestra el rango de resultados de ensayos en ladrillos individuales LEPS, estableciendo máximos, cuartiles y mínimo para los ladrillos ensayados en forma individual.

Las tablas 5 y 6 muestran (respecto de lo observado para CLCH) resultados obtenidos en CLEPS, registrando valores máximos, estadísticos correspondientes, cuartiles y rango de magnitud de los parámetros analizados.

La Fig. 13 muestra las fallas registradas en ladrillos individuales, observándose una separación del ladrillo respecto del núcleo de mortero de cemento. La fisura vertical observada denota el ensanchamiento producido por el efecto de compresión.

Tabla 2. Resumen estadístico de caracterización de celdas de ladrillos CLCH.

Parámetros estadísticos	L1 [mm]	L2 [mm]	H [mm]	R CLCH-CA [MPa]	R CLCH-AC [MPa]	E CLCH-CA [MPa]	E CLCH-AC [MPa]
Media	173.63	374.68	359.13	4.66	10.66	1673.19	7257.44
Desvío típico	1.21	2.93	0.98	0.321	1.32	22.67	1392.97
Variación %	0.697%	0.782%	0.274%	6.88%	12.34%	1.35%	19.19%
Asimetría	-1.42	-0.05	0.80	-0.02	1.26	0.01	-0.07
Curtosis	2.46	-5.72	-1.48	0.2	1.02	0.07	-1.75

Tabla 3. Resumen estadístico de propiedades mecánicas de ladrillos individuales LEPS a compresión.

LEPS	Media	Desvío	CV	Asimetría	Curtosis
Carga máxima [Kg]	4961.82	1128.54	0.23	-0.86	2.07
Acortamiento correspondiente [mm]	2.99	1.76	0.59	0.37	-0.10
Tensión de rotura [MPa]	16.75	4.15	0.25	-0.60	0.93
Deformación específica	0.02	0.01	0.59	0.39	-0.12
Rampa de carga [Kg/s]	47.27	26.49	0.56	0.13	-1.52

Tabla 4. Resumen por cuartiles de propiedades mecánicas de ladrillos EPS a compresión.

LEPS	Máximo	3er cuartil	2do cuartil	1er cuartil	Mínimo
Carga máxima [Kg]	7728.02	5549.03	4804.61	4422.88	2965.88
acortamiento [mm]	6.17	3.97	3.30	2.43	-0.05
Tensión de rotura [MPa]	26.08	18.93	15.88	14.51	9.43
Deformación específica	5.1E-02	3.3E-02	2.7E-02	2.0E-02	-4.2E-04
Rampa de carga [Kg/s]	80.24	70.71	49.31	25.17	2.90



Fig. 13. Modos de falla en ensayos de ladrillos individuales.

Tabla 5. Resumen estadístico de propiedades mecánicas de celdas de ladrillos CLEPS.

CLEPS	Media	Desvío	CV	Asimetría	Curtosis
Carga máxima [Kg]	10307.49	2451.32	0.24	0.59	-0.93
Tensión de rotura [MPa]	21.09	4.06	0.19	0.57	-0.83
Rampa de carga [kg/s]	284.92	326.44	1.15	0.67	-1.83

Las tablas 6 y 7 muestran los resultados estadísticos obtenidos para los ensayos normalizados en morteros de resistencia a flexión.

Tabla 6. Resumen por cuartiles de propiedades mecánicas de celdas de ladrillos EPS.

CLEPS	Mínimo	1er Cuartil	Media	3er Cuartil	Máximo
Carga máxima [Kg]	7675.83	8212.80	9637.56	12290.19	15035.90
Tensión de rotura [MPa]	16.62	17.78	19.90	23.84	29.12
Rampa de carga [Kg/s]	46.20	49.60	53.05	696.49	728.80

Para los ensayos de morteros a flexión a partir de la Norma IRAM 1622, se siguió el procedimiento indicado usando la ecuación (6) para obtener la resistencia.

$$\overline{R_f} = \frac{1,5 \cdot F_f \cdot l}{b^3} \quad (6)$$

donde:

- R_f : Resistencia a flexión
- l : Distancia entre apoyos
- F_f : Carga
- b : Lado de la sección.

En la tabla 7 se puede observar que los parámetros registrados han mostrado valores de asimetría y curtosis que permiten concluir que dichos parámetros son compatibles con una distribución de tipo normal. En la tabla 8 se ordenaron valores organizados por cuartiles; y con respecto a los valores obtenidos para resistencia a compresión, los cuales están presentados en la

tabla 8, se constató que la relación entre la resistencia a flexión y a compresión fue del orden del 16 %, valor típico de materiales de comportamiento frágil.

Tabla 7. Resumen estadístico de propiedades mecánicas de probetas de mortero MC a flexión.

FMC	Media	Desvío	CV	Asimetría	Curtosis
Carga máxima registrada [Kg]	202.29	67.66	0.33	-0.09	-0.07
Resistencia experimental [MPa]	5.15	1.75	0.34	0.06	-0.03
Rampa de carga [Kg/s]	4.66	0.51	0.11	0.97	0.24
Resistencia esperada [Mpa]	7.44	2.49	0.33	-0.09	-0.07

Tabla 8. Resumen por cuartiles de propiedades mecánicas de probetas de mortero MC a flexión.

FMC	Mínimo	1er cuartil	Mediana	3er cuartil	Máximo
Carga máxima registrada [Kg]	77.16	167.98	218.13	232.26	321.76
Resistencia experimental [MPa]	2.01	4.19	5.35	5.93	8.41
Rampa de carga [Kg/s]	4.13	4.27	4.50	5.03	5.84
Resistencia esperada [MPa]	2.84	6.18	8.02	8.54	11.83

La Fig. 14 muestra los modos de falla ocurridos en los ensayos de resistencia a tracción por flexión para las barras normalizadas de mortero.



Fig. 14. Modos de falla en ensayos de probetas de mortero MC ensayados a flexión.



Fig. 15. Modos de falla en ensayos de probetas de mortero MC ensayados a compresión.

Para los ensayos de morteros a compresión, los resultados se observan en las tablas 9 y 10, donde se puede apreciar que la función continua de probabilidad se puede ajustar a una distribución normal. La Fig. 15 muestra el modo típico de falla ocurrido en los ensayos de resistencia a compresión para barras normalizadas de mortero.

Tabla 9. Resumen estadístico de propiedades mecánicas de probetas de mortero MC a compresión.

CMC	Media	Desvío	CV	Asimetría	Curtosis
Carga máxima [Kg]	4769.03	821.24	0.17	0.66	-0.42
Tensión de rotura [Mpa]	31.53	5.43	0.17	0.66	-0.42
Velocidad de carga [Kg/s]	243.86	11.36	0.05	0.13	-1.18

Tabla 10. Resumen por cuartiles de propiedades mecánicas de probetas de mortero MC a compresión.

CMC	Mínimo	1er cuartil	Mediana	3er cuartil	Máximo
Carga máxima [Kg]	3465.98	4149.72	4654.48	5277.36	6473.02
Tensión de rotura [MPa]	22.92	27.44	30.77	34.89	42.80
Velocidad de carga [Kg/s]	226.54	235.72	241.57	254.00	263.32

4. Conclusiones

A continuación, desarrollamos las conclusiones del presente trabajo basado en comparar las prestaciones mecánicas de muros realizados con tecnología LEPS respecto de otros sistemas conocidos, con el objetivo de establecer criterios de factibilidad de uso del sistema propuesto.

En primer lugar, se comparó la resistencia a compresión entre ladrillos EPS rellenos con mortero de cemento y ladrillos LCH unidos con mortero. Los resultados estadísticos demuestran que los parámetros obtenidos en el presente artículo pueden adaptarse a una función de distribución de probabilidad continua de tipo normal. La importancia de este punto es confirmar el tipo de distribución a aplicar. En trabajos futuros se puede usar este dato como referencia para cualquier proceso de optimización con restricciones de confiabilidad.

Con respecto a la comparativa entre opciones, puede observarse que, en el caso de la alternativa EPS, en celdas y en ladrillos unitarios, la resistencia mostró mayor orden de magnitud; aun así, el orden de variación de los resultados superó el 15% lo cual permite concluir, que es consecuencia de la diferencia entre materiales en términos de sus propiedades mecánicas. Al contrario, en ladrillos LCH y en celdas de mampostería LCH, la resistencia fue menor en general, pero el orden de variación fue menor al 15%, con lo cual la alternativa LCH parece ser más estable y admitir valores característicos mayores.

Con respecto a la diferencia entre resultados en ladrillos y celdas LCH, se puede concluir que el mortero de junta incide de manera considerable en el resultado final, ocasionando una disminución en la resistencia, compresión del conjunto.

Respecto a trabajos futuros se puede plantear un análisis de la resistencia al corte en comparativa de ambos sistemas con el cual se puede estimar el desempeño de estos frente a acciones dinámicas, como el sismo. En cuanto a la resistencia a flexión de LEPS y CLEPS, es interesante pensar en estudiar este fenómeno para establecer posibles modos de falla no considerados a la fecha.

Por otro lado, al evaluar la incidencia del mortero de junta en LCH, se propone analizar cómo se modifica la resistencia a compresión en el conjunto utilizando morteros mejorados mecánicamente y con menos espesor, los cuales se espera aproximar el comportamiento de la celda al comportamiento observado en los ladrillos individuales.

Para finalizar al margen de lo mencionado en las conclusiones es importante señalar que ambas alternativas se pueden considerar viables como opciones para viviendas de baja altura, con bajo compromiso estructural, en donde las opciones, con las reservas del caso, pueden considerarse aplicables en cerramientos exteriores e interiores, bajo condiciones de sollicitación estructural controlada y acotada. Los valores obtenidos en los experimentos son compatibles con la utilización de estos sistemas como soportes de entresijos con sobrecarga de uso destinada a viviendas.

Referencias

- [1] CPAU, a-406 planilla resumen de costos de obra e incidencia de rubros, Manual del Ejercicio Profesional de Arquitectura y Urbanismo, 9ª edición, 2023.
- [2] Duarte J., “interacción estructural de cuerpos edilicios en Misiones, Argentina”, Tesis doctoral, Doctorado en Ciencias Aplicadas, Facultad de Ciencias Exactas Químicas y Naturales, Universidad Nacional de Misiones. Misiones, Argentina, 2021.
- [3] Oller S., Numerical simulation of mechanical behavior of composite materials, Centre Internacional de mètodes Numèrics en Enginyeria (CIMNE), School of Civil Engineering, Universitat Politècnica de Catalunya (UPC), Barcelona, Spain, Springer, (2014).

- [4] Norma IRAM 12586. Ladrillos y bloques cerámicos para la construcción de muros. Método de ensayo de resistencia a la compresión. Reemplaza a IRAM 12586: 1980. Subcomité Ladrillos y Bloques Cerámicos para la Construcción. Instituto Argentino de Normalización y Certificación
- [5] Vázquez J., “estudio técnico y económico de una vivienda social utilizando ladrillos de poliestireno expandido”, Universidad Austral de Chile, Facultad de Ciencias de Ingeniería, Escuela de Construcción Civil, Tesis para optar al Título de Ingeniera Constructor, Valdivia-Chile, 2010.
- [6] Padilla K., “sistema comparativo costo y tiempo de la mampostería tradicional vs mampostería (EPS) poliestireno en el hospital monte sinai “bloque e-100”, Trabajo de titulación para obtener el grado de Ingeniero Civil, Escuela De Ingeniería, Facultad De Ciencias Matemáticas y Físicas, Universidad De Guayaquil, Guayaquil, Ecuador, 2017.
- [7] Norma IRAM 1622. Cemento Portland. Determinación de resistencias mecánicas. Reemplaza a IRAM EXP 1622 (Exp):2006. Incluye Modificación N°1: 2010. Incluye Modificación N°2: 2015. Incluye Modificación N°3: 2022. Instituto Argentino de Normalización y Certificación.
- [8] Norma IRAM 12737. Mampostería de ladrillos y bloques cerámicos. Método para determinar la resistencia a la compresión de muros mediante el ensayo de pilas de mampostería. Subcomité Ladrillos y Bloques Cerámicos para la Construcción. Instituto Argentino de Normalización y Certificación.
- [9] Park, R., Paulay, T. Estructuras de concreto reforzado, Primera Edición, México, Editorial Limusa, 1979.-
- [10] Reglamento CIRSOC 501, Estructuras de mampostería, Ministerio de Planificación Federal, Inversión Pública y Servicios.
- [11] Reglamento CIRSOC 501-E, Viviendas de mampostería bajo compromiso estructural, Ministerio de Planificación Federal, Inversión Pública y Servicios.
- [12] Reinert H.O., evaluación de solicitaciones por elementos finitos aplicada a medios continuos, Departamento de Ingeniería Civil, Facultad de Ingeniería, Universidad Nacional de Misiones, Mecánica Computacional, Vol XXXII. Number 42. Structural Analysis, ISSN 2591-3522, 2013.
- [13] Duarte, J. A. (2017). Aproximación del comportamiento de ladrillos cerámicos: calibración experimental y numérica (Mecánica Computacional, Vol. XXXV, pp. 2077–2091). Universidad Nacional de La Plata.
- [14] Sobhani M., (2025), Fabrication of lightweight clay-based refractory bricks using recycled EPS polymer, Faculty of Materials & Metallurgical Engineering, Semnan University, Iran, Case Studies in Construction Materials, Volume 22, July 2025, e04683, Elsevier.
- [15] Villalta-Góngora, V., González-Tobar, E., & Valero-Fajardo, C. (2023). Diseño de un bloque alivianado utilizando poliestireno expandido, PET, vermiculita como agregados. 593 Digital Publisher CEIT, 8(3), 383-394. <https://doi.org/10.33386/593dp.2023.3.1708>.

Es una publicación
de la Universidad Nacional de Misiones,
Facultad de Ingeniería. Argentina.



**UNIVERSIDAD
NACIONAL
DE MISIONES**



**FACULTAD
DE INGENIERÍA
UNaM**