

**UNIVERSIDAD NACIONAL MICAELA BASTIDAS DE APURÍMAC**  
**FACULTAD DE INGENIERÍA**

ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA CIVIL



Tesis

Modelos de Machine Learning para la predicción de la resistencia al  
corte en la unión viga-columna, 2025

Presentado por:

Fredy Aguirre Ramos

Para optar el título de Ingeniero Civil

Abancay, Perú

2025



**UNIVERSIDAD NACIONAL MICAELA BASTIDAS DE APURÍMAC**  
**FACULTAD DE INGENIERÍA**  
**ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA CIVIL.**



**TESIS**

**Modelos de Machine Learning para la predicción de la resistencia al corte en la unión  
viga-columna, 2025**

Presentado por **Fredy Aguirre Ramos**, para optar el título de Ingeniero Civil

Sustentado y aprobado el día 20 de enero de 2026 ante el jurado evaluador:

**Presidente:**

*Dr. Calixto Cañari Otero*

**Primer miembro:**

*Mtro. Juan Franks Valenzuela Carrasco*

**Segundo miembro:**

*Dr. Wilfredo Soto Palomino*

**Asesor:**

*Mtro. Yhon Fuentes Huamán*



*Año del Fortalecimiento de la Soberanía Nacional*

## CONSTANCIA DE ORIGINALIDAD N° 011-2026

La Universidad Nacional Micaela Bastidas de Apurímac, a través de la Unidad de investigación de la Facultad de Ingeniería declara que, la tesis titulada: **MODELOS DE MACHINE LEARNING PARA LA PREDICCIÓN DE LA RESISTENCIA AL CORTE EN LA UNIÓN VIGA-COLUMNA, 2025** presentado por el Bach. **Fredy Aguirre Ramos**, para optar el título de **Ingeniero Civil**; ha sido sometido a un mecanismo de evaluación y verificación de similitud, a través del Software Turnitin, siendo el índice de similitud **ACEPTABLE** de (5%) por lo que, cumple con los criterios de originalidad establecidos por la Universidad.

Abancay, 14 de enero del 2026

Atentamente,



UNIVERSIDAD NACIONAL MICAELA BASTIDAS  
FACULTAD DE INGENIERÍA  
Dra. Hesméralda Rojas Enriquez  
DIRECTORA DE LA UNIDAD DE INVESTIGACIÓN  
FACULTAD DE INGENIERÍA

C. c.  
Archivo  
REG. N° 042

## **Agradecimiento**

*Expreso mi más sincero agradecimiento a mi asesor de tesis, por su orientación, dedicación y valiosas recomendaciones a lo largo del desarrollo de esta investigación. Su experiencia y criterio académico fueron determinantes para la correcta conducción y culminación de este trabajo.*

*Agradezco también a los docentes de la especialidad, cuyas enseñanzas y conocimientos adquiridos durante la formación universitaria sentaron las bases técnicas necesarias para el desarrollo de esta tesis.*

*De manera especial, agradezco a mi familia; a mi mamá Aurora Ramos Ccuno, mi hermano Raymundo, mi hermana Eliana y a Kira por el apoyo constante, la paciencia y el aliento brindado en cada etapa del proceso. Su confianza y motivación fueron un pilar fundamental para la culminación de este trabajo.*

*Finalmente, agradezco a todas las personas e instituciones que facilitaron información, recursos y apoyo técnico, contribuyendo de manera significativa al desarrollo de la presente investigación.*



## **Dedicatoria**

*Dedico la presente tesis a mi familia, por su apoyo incondicional, comprensión y confianza a lo largo de todo este proceso académico. Su respaldo constante ha sido fundamental para superar cada desafío y alcanzar este objetivo profesional, de manera especial a mi querida mamá Aurora Ramos Ccuno que ha dado hasta lo que no tenía, lo que soy es gracias a ella.*

*Asimismo, dedico este trabajo a todas las personas que, directa o indirectamente, contribuyeron a mi formación académica y personal, y que con su ejemplo y motivación impulsaron mi interés por la ingeniería estructural y la investigación.*



Modelos de Machine Learning para la predicción de la resistencia al corte en la unión viga-  
columna, 2025

Línea de investigación: Ingeniería de la construcción

Esta publicación está bajo una Licencia Creative Commons



## ÍNDICE

	<b>Pág.</b>
<b>INTRODUCCIÓN</b>	1
<b>RESUMEN</b>	2
<b>ABSTRACT</b>	3
<b>CAPÍTULO I</b>	4
<b>PLANTEAMIENTO DEL PROBLEMA</b>	4
1.1 Descripción del problema	4
1.2 Enunciado del problema	6
1.2.1 Problema general	6
1.2.2 Problemas específicos	6
1.3 Justificación de la investigación	7
1.3.1 Conveniencia	7
1.3.2 Relevancia social	8
1.3.3 Implicancias prácticas	8
<b>CAPÍTULO II</b>	9
<b>OBJETIVOS</b>	9
2.1 Objetivos de la investigación	9
2.1.1 Objetivo general	9
2.1.2 Objetivos específicos	9
2.2 Operacionalización de variable	10
2.2.1 Variable	10
<b>CAPÍTULO III</b>	11
<b>MARCO TEÓRICO REFERENCIAL</b>	11
3.1 Antecedentes	11
3.1.1 Antecedentes internacionales	11
3.1.2 Antecedentes nacionales	13
3.2 Marco teórico	14
3.2.1 Machine Learning (ML)	14
3.2.2 Modelos de resistencia al corte de la unión viga columna	20
3.3 Marco conceptual	26
<b>CAPÍTULO IV</b>	29
<b>METODOLOGÍA</b>	29
4.1 Tipo y nivel de investigación	29



4.1.1	Tipo de investigación	29
4.1.2	Nivel de investigación	29
4.2	Diseño de la investigación	29
4.3	Descripción ética de la investigación	30
4.4	Población y muestra	30
4.4.1	Población	30
4.4.2	Muestra	31
4.5	Procedimiento	31
4.6	Técnica e instrumentos	33
4.6.1	Técnicas de recolección de datos	33
4.6.2	Instrumentos	34
<b>CAPÍTULO V</b>		<b>35</b>
<b>RESULTADOS Y DISCUSIONES</b>		<b>35</b>
5.1	Análisis de resultados	35
5.1.1	Conjunto de datos y selección de características	35
5.1.2	Entrenamiento y selección del modelo	40
5.1.3	Optimización y validación del modelo final	55
5.1.4	Explicabilidad de los modelos predictivos	76
5.2	Discusión	90
5.2.1	Comparación del desempeño entre enfoques de modelado	90
5.2.2	Comparación del desempeño predictivo global	91
5.2.3	Análisis del sobreajuste y capacidad de generalización	91
5.2.4	Influencia del diseño del dataset	92
5.2.5	Explicabilidad global y local (SHAP)	93
<b>CAPÍTULO VI</b>		<b>95</b>
<b>CONCLUSIONES Y RECOMENDACIONES</b>		<b>95</b>
6.1	Conclusiones	95
6.2	Recomendaciones	98
<b>REFERENCIAS BIBLIOGRÁFICAS</b>		<b>101</b>

## ÍNDICE DE TABLAS

	Pág.
<b>Tabla 1</b> — Operacionalización de las variables	10
<b>Tabla 2</b> — Información estadística de los parámetros del dataset 1.	36
<b>Tabla 3</b> — Información estadística de los parámetros del dataset 2.	36
<b>Tabla 4</b> — Información estadística de los parámetros del dataset 3.	37
<b>Tabla 5</b> — Métricas de desempeño de los modelos de Ensemble Learning durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 1	41
<b>Tabla 6</b> — Métricas de desempeño de los modelos de Ensemble Learning durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 2	43
<b>Tabla 7</b> — Métricas de desempeño de los modelos de Ensemble Learning durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 3	45
<b>Tabla 8</b> — Métricas de desempeño de modelos SVM durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 1	47
<b>Tabla 9</b> — Métricas de desempeño de modelos SVM durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 2	48
<b>Tabla 10</b> — Métricas de desempeño para modelos SVM durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 3	50
<b>Tabla 11</b> — Métricas de desempeño de los modelos ANN durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 1	52
<b>Tabla 12</b> — Métricas de desempeño de los modelos ANN durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 2	54
<b>Tabla 13</b> — Métricas de desempeño de los modelos ANN durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 3	55
<b>Tabla 14</b> — Optimización de hiperparámetros de modelos de Ensemble Learning	56
<b>Tabla 15</b> — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 1	60



<b>Tabla 16</b> — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 2	61
<b>Tabla 17</b> — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 3	64
<b>Tabla 18</b> — Métricas de desempeño del modelo SVM optimizado para el dataset 1	67
<b>Tabla 19</b> — Métricas de desempeño del modelo SVM optimizado para el dataset 2	68
<b>Tabla 20</b> — Métricas de desempeño del modelo SVM optimizado para el dataset 3	69
<b>Tabla 21</b> — Métricas de desempeño de modelos ANN optimizados para el dataset 1	71
<b>Tabla 22</b> — Métricas de desempeño de modelos ANN optimizados para el dataset 2	74
<b>Tabla 23</b> — Métricas de desempeño de modelos ANN optimizados para el dataset 3	76
<b>Tabla 24</b> — Valores SHAP del modelo CatBoost para el dataset 1 para la explicación local de los especímenes seleccionados	87
<b>Tabla 25</b> — Valores SHAP del modelo CatBoost para el dataset 2 para la explicación local de los especímenes seleccionados	88
<b>Tabla 26</b> — Valores SHAP del modelo CatBoost para el dataset 3 para la explicación local de los especímenes seleccionados	90



## ÍNDICE DE FIGURAS

	Pág.
<b>Figura 1</b> — Gráfico de dispersión de las características finales del dataset 1.	35
<b>Figura 2</b> — Gráfico de dispersión de las características finales del dataset 2.	36
<b>Figura 3</b> — Gráfico de dispersión de las características finales del dataset 3.	37
<b>Figura 4</b> — Matriz de coeficientes de correlación para el dataset (a) 1, (b) 2 y (c) 3.	40
<b>Figura 5</b> — Resultados de modelos de Ensemble Learning para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 1	42
<b>Figura 6</b> — Resultados de modelos de Ensemble Learning para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 2	44
<b>Figura 7</b> — Resultados de modelos de Ensemble Learning para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 3	45
<b>Figura 8</b> — Resultados de modelos SVM para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 1	47
<b>Figura 9</b> — Resultados de modelos SVM para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 2	49
<b>Figura 10</b> — Resultados de modelos SVM para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 3	51
<b>Figura 11</b> — Resultados de modelos ANN para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 1	53
<b>Figura 12</b> — Resultados de modelos ANN para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 2	54
<b>Figura 13</b> — Resultados de modelos ANN para la validación cruzada en términos de (a) $R^2$ y (b) RMSE para el dataset 3	55
<b>Figura 14</b> — Búsqueda en cuadrícula de los hiperparámetros óptimos del modelo CatBoost para el dataset 1	57
<b>Figura 15</b> — Búsqueda en cuadrícula de los hiperparámetros óptimos del modelo CatBoost para el dataset 2	57
<b>Figura 16</b> — Búsqueda en cuadrícula de los hiperparámetros óptimos del modelo CatBoost para el dataset 3	58

<b>Figura 17</b> — Resultados de la resistencia al corte predichos por diferentes modelos de Ensemble Learning para el dataset 1	60
<b>Figura 18</b> — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 1	61
<b>Figura 19</b> — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 2	62
<b>Figura 20</b> — Resultados de la resistencia al corte predichos por diferentes modelos de Ensemble Learning para el dataset 2	63
<b>Figura 21</b> — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 3	64
<b>Figura 22</b> — Resultados de la resistencia al corte predichos por diferentes modelos de Ensemble Learning para el dataset 3	65
<b>Figura 23</b> — Resultado de la resistencia al corte predicho por el modelo SVM optimizado para el dataset 1	67
<b>Figura 24</b> — Resultado de la resistencia al corte predicho por el modelo SVM optimizado para el dataset 2	68
<b>Figura 25</b> — Resultado de la resistencia al corte predicho por el modelo SVM optimizado para el dataset 3	70
<b>Figura 26</b> — Resultado de la resistencia al corte predicho por el modelo ANN_Wide optimizado para el dataset 1	72
<b>Figura 27</b> — Resultado de la resistencia al corte predicho por el modelo ANN_Medium optimizado para el dataset 2	74
<b>Figura 28</b> — Resultado de la resistencia al corte predicho por el modelo ANN_Wide optimizado para el dataset 3	76
<b>Figura 29</b> — Explicación global del modelo CatBoost para el dataset 1 mediante (a) Importancia de características y (b) Gráfico resumen de SHAP	78
<b>Figura 30</b> — Gráficos de dependencia de características SHAP del modelo CatBoost para el dataset 1 para (a) $\rho bfc'$ , (b) $\rho cfc'$ , (c) $\rho jtfc'$ y (d) $fyb$	81
<b>Figura 31</b> — Explicación global del modelo CatBoost para el dataset 2 mediante (a) Importancia de características y (b) Gráfico resumen de SHAP.	83
<b>Figura 32</b> — Explicación global del modelo CatBoost para el dataset 3 mediante (a) Importancia de características y (b) Gráfico resumen de SHAP.	84

- Figura 33** — Explicación local del modelo CatBoost para el dataset 1 mediante valores SHAP de los especímenes seleccionados: (a) espécimen A0 de Adachi et al. (1995); y (b) espécimen LVP4 de Alva et al. (2007). 86
- Figura 34** — Explicación local del modelo CatBoost para el dataset 2 mediante valores SHAP de los especímenes seleccionados: (a) espécimen A0 de Adachi et al. (1995); y (b) espécimen LVP4 de Alva et al. (2007). 88
- Figura 35** — Explicación local del modelo CatBoost para el dataset 3 mediante valores SHAP de los especímenes seleccionados: (a) espécimen A0 de Adachi et al. (1995); y (b) espécimen LVP4 de Alva et al. (2007). 89

## INTRODUCCIÓN

En la actualidad la inteligencia artificial (IA) está transformando diversas industrias; en la ingeniería civil, nos permite clasificar y predecir propiedades que son importantes para las diferentes ramas especializadas de la ingeniería civil (estructuras, geotecnia, hidráulica, transporte y construcción), es por eso que, teniendo en consideración los tiempos modernos la presente investigación titulado: "Modelos de Machine Learning para la predicción de la resistencia al corte en la unión viga-columna, 2025", se desarrolló con el objetivo de abordar la problemática de la predicción de la resistencia al corte en la unión viga-columna , basados en ensayos experimentales con modelos de Machine Learning, que es una rama de la IA.

La investigación se enfocó en el desarrollo y validación de modelos predictivos avanzados utilizando técnicas de Machine Learning para determinar la resistencia al corte en uniones viga-columna, elementos estructurales cuyo comportamiento es crucial en las edificaciones. El estudio parte del reconocimiento de las limitaciones existentes en los métodos tradicionales de cálculo, los cuales frecuentemente simplifican la compleja naturaleza no lineal del comportamiento estructural bajo cargas cíclicas.

Mediante la implementación de múltiples algoritmos de aprendizaje automático se estableció un marco comparativo que permitió identificar al modelo catboost como aquel que mantiene valores elevados de  $R^2$  en testing (0.84, 0.835 y 0.893 respectivamente) acompañado de menores errores (RMSE, MAE, MARD, D1) en comparación con el resto de los modelos. La investigación incorporo además técnicas de Explainable AI (XAI), específicamente análisis SHAP (Shapley Additive Explanations), para garantizar la interpretabilidad de los resultados y facilitar la identificación de las variables más influyentes en el mecanismo resistente.

La metodología empleada integro y proceso 596 datos experimentales provenientes de literatura técnica especializada, que abarcan diversas configuraciones geométricas, propiedades de materiales y condiciones de carga. El proceso de validación incluyo; técnicas de cross-validation y métricas de evaluación ( $R^2$ , RMSE, MAE).



## RESUMEN

La resistencia al corte en la unión viga–columna constituye uno de los mecanismos críticos en el desempeño sísmico de estructuras de concreto armado (evita una posible falla frágil y asegura el comportamiento dúctil) además, se encarga de hacer cumplir el mecanismo de viga débil columna fuerte debido a la compleja interacción entre variables geométricas, mecánicas y tipológicas que existen en la unión viga-columna. Los modelos analíticos y empíricos tradicionales presentan limitaciones para representar rigurosamente los diversos factores que intervienen en la unión viga columna, esto motivo a desarrollar esta investigación, además de emplear la inteligencia artificial (Machine Learning) como herramienta alternativa de predicción.

Con el fin de predecir la resistencia al corte en la unión viga-columna en esta investigación, se desarrollaron modelos de Machine Learning, de distintos enfoques como: modelos de Ensemble Learning (Random Forest, AdaBoost, Gradient Boosting, XGBoost, LightGBM y CatBoost); Máquinas de Soporte Vectorial (SVM) y Redes Neuronales Artificiales (ANN), analizados en función a tres datasets con diferente nivel de complejidad y selección de variables, diseñados progresivamente con base en criterios físicos y mecánicos, los modelos se optimizaron mediante Grid Search y validaron mediante: validación cruzada de cinco pliegues; métricas de desempeño global y local ( $R^2$ , RMSE, MAE, MARD y D10).

Los resultados mostraron que los modelos de Ensemble Learning tienen el mejor desempeño global en los tres datasets, la ingeniería de características basada en principios estructurales y el análisis de explicabilidad confirmaron que las variables más influyentes coinciden con los mecanismos resistentes clásicos, CatBoost como modelo Ensemble Learning demostró elevados valores de  $R^2$  (0.84, 0.835 y 0.893) y errores reducidos: RMSE = 0.992; MAE = 0.691; MARD = 0.109 y  $D_{10\%}$  = 6.11 en testing, quedando demostrado estadísticamente que el modelo CatBoost es una herramienta confiable para la predicción de la resistencia al corte en la unión viga-columna

**Palabras clave:** *catboost, machine learning, resistencia al corte, unión viga–columna.*



## ABSTRACT

The Shear strength in reinforced concrete beam–column joints represents a critical mechanism governing the seismic performance of structural systems, as it prevents brittle joint failure and ensures the development of ductile global behavior in accordance with the weak-beam–strong-column philosophy. The joint response is inherently complex due to the coupled interaction among geometric, mechanical, and typological parameters. Conventional analytical and empirical models exhibit inherent limitations in rigorously representing this multifactorial and nonlinear behavior. These limitations motivate the present study, which explores Machine Learning (ML) as a data-driven alternative for accurate shear strength prediction.

To this end, several ML models were developed and comparatively evaluated, including Ensemble Learning approaches (Random Forest, AdaBoost, Gradient Boosting, XGBoost, LightGBM, and CatBoost), Support Vector Machines (SVM), and Artificial Neural Networks (ANN). The models were trained and tested using three progressively constructed datasets with increasing levels of complexity and variable refinement, defined based on mechanical reasoning and structural principles. Hyperparameter optimization was conducted using Grid Search, and model robustness was assessed through five-fold cross-validation. Performance was quantified using both global and local evaluation metrics ( $R^2$ , RMSE, MAE, MARD, and D10).

The results demonstrate that Ensemble Learning algorithms consistently outperform other approaches across all datasets. Feature engineering grounded in structural mechanics, together with explainability analysis, confirmed that the most influential predictors align with classical shear-resisting mechanisms. Among all evaluated models, CatBoost achieved superior predictive accuracy, with high coefficients of determination ( $R^2 = 0.84, 0.835, \text{ and } 0.893$ ) and low prediction errors (RMSE = 0.992; MAE = 0.691; MARD = 0.109; D10% = 6.11) in the testing phase. Statistical evidence confirms that CatBoost provides a reliable and robust framework for predicting shear strength in reinforced concrete beam–column joints.

**Keywords:** *beam–column joint, catboost, machine learning, shear strength.*



## CAPÍTULO I PLANTEAMIENTO DEL PROBLEMA

### 1.1 Descripción del problema

La resistencia al corte en la unión viga-columna es una capacidad muy importante de la estructura, cuando ocurre un sismo en este punto se concentran altos esfuerzos de corte, que son mayores a los que se presentan en columnas o vigas de manera independiente.

Fallas en el diseño de la unión viga-columna pueden generar daños graves a las infraestructuras, como por ejemplo; el colapso parcial por fallas estructurales del edificio Space Medellín, Colombia, (2013) y los daños ocasionados por el terremoto de Kunamoto – Japon, en abril del 2016 fueron muestras claras de las deficiencias en la unión viga-columna.

En la actualidad, los códigos de diseño estructural vigentes en la mayoría de los países como el NZS 3101.1&2:2006 (Nueva Zelanda), Eurocode 8 (EN 1998-1), el código chino GB, el AIJ (Japón), el ACI 318-19, el ACI 352R-02, y el ASCE 41-17 establecen expresiones únicas para estimar la resistencia al corte de las uniones viga-columna exteriores e interiores, basadas principalmente en la resistencia a compresión del concreto. Sin embargo, múltiples investigaciones experimentales y analíticas como por ejemplo de Vollum & Newman (1999) y Cagley et al. (2010) han evidenciado que este enfoque resulta insuficiente para describir el comportamiento real de dichas uniones, ya que la resistencia al corte está influenciada por un conjunto de factores interrelacionados, como la geometría de la unión, la cuantía de refuerzo transversal, la cuantía de refuerzo longitudinal en la viga, y la carga axial de la columna.

A lo largo de las últimas décadas, diversos modelos analíticos y computacionales han sido desarrollados con el objetivo de predecir el comportamiento de las uniones viga-columna, tanto interiores como exteriores. Entre ellos, se destacan el Modified Compression Field Theory propuesto por Hwang et al., y los modelos de biela y tirante (strut-and-tie) elaborados por Hsu et al., posteriormente modificados por Wong et al. y Pang y Hsu. De



igual forma, Pauletta et al. propusieron un modelo para uniones exteriores basándose en la misma analogía. Sin embargo, la principal limitación de estos enfoques radica en su dependencia del juicio del diseñador, ya que requieren interpretaciones subjetivas y experiencia previa para definir los parámetros de diseño, lo que introduce incertidumbre y falta de reproducibilidad en los resultados.

Por otro lado, se han desarrollado modelos empíricos simplificados que buscan describir el comportamiento cortante de las uniones exteriores mediante relaciones experimentales. Vollum et al. plantearon una expresión que relaciona la resistencia al corte con la relación de aspecto de la unión y la resistencia del concreto, aunque su aplicación se restringe a ensayos monotónicos. Posteriormente, Bakir et al. propusieron una ecuación que incorpora la resistencia del concreto y la cuantía de refuerzo longitudinal de la viga, mientras que Hegger et al. modificaron este modelo reemplazando el refuerzo de la viga por el de la columna. Otras contribuciones relevantes incluyen los trabajos de Sarsam et al., Parra-Montesinos et al. y Kim et al., quienes integraron diversos factores influyentes en la estimación de la resistencia.

El análisis comparativo de los modelos mecánicos utilizados para estimar la resistencia al corte en uniones viga-columna evidencia una problemática central: la falta de consistencia y precisión predictiva entre los principales modelos propuestos en la literatura. Esta situación se hace evidente al revisar los indicadores estadísticos de desempeño, donde se observan marcadas variaciones en los valores promedio (AVG) y coeficientes de variación (COV).

Algunos modelos presentan sobrestimación de la resistencia, como el de Tsonos (AVG = 0.82; COV = 0.28), lo que genera predicciones no conservadoras que pueden comprometer la seguridad estructural. Otros modelos muestran subestimación moderada, tal como ocurre con Bakir y Boduroğlu (AVG = 1.29; COV = 0.17) y LaFave y Kim (AVG = 1.17; COV = 0.18), lo cual conduce a diseños sobredimensionados y repercute en mayores costos constructivos. Asimismo, algunos modelos exhiben subestimación severa, como los de Hwang y Lee (AVG = 1.54; COV = 0.33) y Parker y Bullman (AVG = 2.00; COV = 0.35), evidenciando una capacidad predictiva deficiente. Si bien el modelo de Volium y Newman (AVG = 0.97; COV = 0.14) muestra un desempeño comparativamente superior, ningún modelo logra una predicción robusta y confiable en



todos los escenarios evaluados. Esta heterogeneidad en los resultados refleja la ausencia de un método predictivo consistente que capture adecuadamente los mecanismos resistentes y la complejidad física de la unión viga-columna.

La situación problemática se origina en limitaciones conceptuales de los modelos mecánicos, simplificaciones geométricas, falta de calibración con bases de datos actualizadas y variabilidad en los mecanismos de falla, lo que deriva en una brecha significativa entre la resistencia predicha y la resistencia observada. Para superar estas limitaciones es necesario introducir enfoques alternativos que permitan capturar de manera más precisa el comportamiento no lineal y multivariable de las uniones viga-columna. En este sentido, el empleo de modelos basados en aprendizaje supervisado y técnicas avanzadas de inteligencia artificial, particularmente redes neuronales y métodos de Ensemble Learning.

## 1.2 Enunciado del problema

### 1.2.1 Problema general

¿Cómo puede reducirse la dispersión e incertidumbre en la predicción de la resistencia al corte en la unión viga-columna,2025 mediante modelos de Machine Learning como herramientas predictivas basadas en datos experimentales?

### 1.2.2 Problemas específicos

- ¿Qué algoritmos de Machine Learning, individuales y ensamblados, permiten minimizar el error y la variabilidad predictiva en la estimación de la resistencia al corte del nudo viga-columna,2025 dentro del dominio experimental disponible?
- ¿Qué estrategias de validación estadística y análisis de generalización permiten cuantificar la incertidumbre y estabilidad predictiva de los modelos aplicados a la predicción de la resistencia al corte en la unión viga-columna, 2025?
- ¿Qué variables estructurales influyen en mayor y menor medida en la reducción de la incertidumbre predictiva del modelo, según métricas de interpretabilidad como SHAP?



## 1.3 Justificación de la investigación

### 1.3.1 Conveniencia

La investigación es conveniente porque permite desarrollar un modelo predictivo más preciso para la resistencia al corte en uniones viga-columna, problema crítico en el diseño sismorresistente. Sirve para reducir incertidumbre en la ingeniería estructural y proporciona herramientas modernas aplicables a normativas y prácticas de diseño.

- **Necesidad técnica:** Los métodos tradicionales de cálculo presentan limitaciones significativas al modelar el comportamiento complejo y no lineal de las uniones estructurales bajo cargas cíclicas.
- **Herramienta de apoyo:** El modelo de Machine Learning desarrollado para la predicción de la resistencia al corte en la unión viga-columna constituye una herramienta computacional de apoyo orientada a la estimación rápida y eficiente de la capacidad resistente, a partir de parámetros geométricos, mecánicos y de refuerzo previamente definidos.

Es importante señalar que el modelo no sustituye los métodos normativos vigentes, no reemplaza el criterio ingenieril, Su principal ventaja radica en la capacidad de capturar interacciones complejas entre variables que no siempre son consideradas explícitamente en formulaciones empíricas tradicionales.

El modelo únicamente puede emplearse cuando los parámetros de entrada se encuentren dentro del dominio estadístico cubierto por la base de datos de entrenamiento.

El uso del modelo fuera de dichos rangos implica extrapolación, lo cual puede generar estimaciones no confiables debido a: falta de representatividad estadística; incremento de varianza predictiva y pérdida de capacidad de generalización



- **Optimización de recursos:** La capacidad de predecir con exactitud la resistencia al corte facilitará diseños más eficientes, reduciendo tanto el sobredimensionamiento conservador como los riesgos por subestimación.

### 1.3.2 Relevancia social

La investigación posee una marcada relevancia social que trasciende el ámbito técnico, impactando directamente en la seguridad y bienestar colectivo:

- **Protección de vidas humanas:** Las uniones viga-columna son elementos críticos en la respuesta sísmica de estructuras; su falla puede desencadenar colapsos progresivos con consecuencias catastróficas.
- **Desarrollo urbano sostenible:** Contribuye a la construcción de ciudades más seguras mediante el mejoramiento continuo de las prácticas de ingeniería estructural.

### 1.3.3 Implicancias prácticas

Reducción de incertidumbre:

- Minimiza la variabilidad en predicciones que actualmente dependen de simplificaciones normativas.
- Proporciona un marco cuantitativo para la toma de decisiones en diseño sísmico.

## CAPÍTULO II

### OBJETIVOS

#### 2.1 Objetivos de la investigación

##### 2.1.1 Objetivo general

Desarrollar y evaluar un modelo de Machine Learning como herramienta de estimación para reducir la dispersión e incertidumbre en la predicción de la resistencia al corte en la unión viga–columna, 2025 a partir de datos experimentales validados.

##### 2.1.2 Objetivos específicos

- Evaluar y comparar distintos algoritmos de Machine Learning, individuales y ensamblados, con el fin de identificar aquellos que minimicen el error y la variabilidad predictiva en la estimación de la resistencia al corte en la unión viga-columna, 2025.
- Implementar estrategias de validación cruzada y métricas de desempeño estadístico que permitan cuantificar la incertidumbre, robustez y capacidad de generalización del modelo propuesto.
- Analizar la influencia relativa de las variables estructurales mediante técnicas de interpretabilidad (por ejemplo, SHAP), con el propósito de identificar los parámetros de mayor y menor incidencia en la predicción del modelo, sin atribuirles carácter constitutivo directo.

## 2.2 Operacionalización de variable

### 2.2.1 Variable

- Modelos de Machine Learning

Tabla 1 — Operacionalización de las variables

VARIABLE DE ESTUDIO	CONCEPTUALIZACIÓN	DIMENSIONES	INDICADORES	UNIDAD DE MEDIDA	TÉCNICAS E INSTRUMENTOS
<b>Variable:</b> Modelos de Machine Learning	Constituyen algoritmos computacionales diseñados para identificar patrones complejos y relaciones no lineales en conjuntos de datos, permitiendo la construcción de sistemas predictivos basados en aprendizaje automático, representan herramientas matemáticas avanzadas que procesan variables estructurales para generar predicciones cuantitativas sobre el comportamiento mecánico de uniones estructurales.	Ensemble Learning	RF	Métricas de desempeño	Técnica: Observación  Instrumento: Ficha de evaluación
			AdaBoost		
			XGBoost		
			GBRT		
			CatBoost		
			LightGBM		
		SVM	Linear SVM		
			Quadratic SVM		
			Cubic SVM		
			Fine Gaussian SVM		
			Medium Gaussian SVM		
			Coarse Gaussian SVM		
		ANN	Narrow NN		
			Medium NN		
			Wide NN		
Two Layer NN					
Three Layer NN					

## CAPÍTULO III

### MARCO TEÓRICO REFERENCIAL

#### 3.1 Antecedentes

##### 3.1.1 Antecedentes internacionales

- a) Katof et al. (2025), en su investigación “Machine Learning-based prediction of shear strength in interior beam-column joints”, evaluaron la precisión de las normativas internacionales vigentes para predecir la resistencia al corte en nudos viga-columna interiores, identificando limitaciones significativas en los métodos convencionales. A partir de una base de datos de 158 especímenes experimentales, los autores demostraron que las disposiciones normativas existentes subestiman o sobrestiman sistemáticamente la resistencia al corte, con coeficientes de correlación bajos (0.66–0.73) en comparación con los resultados experimentales. Para abordar esta problemática, desarrollaron un modelo basado en redes neuronales artificiales (ANNs) que incorpora variables clave como propiedades geométricas, características de los materiales y condiciones de carga. El modelo logró un coeficiente de correlación de 0.98 con los datos experimentales, superando ampliamente los enfoques normativos. Además, los autores presentaron los parámetros del modelo en formatos accesibles para su implementación práctica en software de hoja de cálculo, facilitando su adopción en el diseño estructural.
  
- b) Kotsovou et al. (2017), en su investigación “Assessment of RC exterior beam-column joints based on artificial neural networks and other methods”, desarrollaron una base de datos integral a partir de más de 150 ensayos experimentales de uniones viga-columna exteriores, utilizada para entrenar y validar un modelo basado en redes neuronales artificiales (ANNs). El modelo de ANN demostró una capacidad predictiva excepcional, alcanzando una precisión superior al 95% en la identificación del modo de falla y mostrando una correlación muy estrecha con los valores de resistencia experimentalmente establecidos. Kotsovou et al. compararon las predicciones del modelo de ANN



con métodos normativos ampliamente utilizados y con un método recientemente propuesto que no requiere calibración mediante datos experimentales. Los resultados confirmaron las limitaciones de los métodos normativos actuales, que no solo mostraron inconsistencias en la predicción de la resistencia, sino también en la identificación del modo de falla, comprometiendo la capacidad de garantizar un diseño sísmico adecuado.

- c) Mangalathu & Jeon (2018), en su investigación “Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using Machine Learning techniques”, implementaron técnicas de Machine Learning para clasificar modos de falla y predecir la resistencia al corte en uniones viga-columna, utilizando una extensa base de datos de 536 ensayos experimentales. El estudio se centró en dos modos de falla principales: falla frágil por cortante en la junta antes de la fluencia de la viga (modo J) y falla dúctil después de la fluencia de la viga (modo BJ). Mangalathu & Jeon evaluaron múltiples algoritmos de clasificación (regresión logística, análisis discriminante, k-vecinos más cercanos, Naïve Bayes, máquinas de soporte vectorial, árboles de decisión y random forest) y técnicas de regresión (lineal, lasso, stepwise, ridge, elastic net y random forest). El modelo de regresión lasso demostró la mejor eficiencia y precisión razonable, logrando: 81% de precisión en la clasificación del modo de falla, ratios experimental-predicción de 0.9845 (modo J) y 1.0302 (modo BJ) y coeficientes de variación de 0.1424 (modo J) y 0.1411 (modo BJ).
- d) Karampinis et al. (2024), en su investigación “Analytical Equations for the Prediction of the Failure Mode of Reinforced Concrete Beam–Column Joints Based on Interpretable Machine Learning and SHAP Values”, estudiaron la brecha entre la precisión de los modelos de Machine Learning y la necesidad de transparencia en aplicaciones de ingeniería estructural. Los autores desarrollaron una metodología novedosa que utiliza SHAP values no solo como herramienta de explicabilidad, sino como variable objetivo para derivar ecuaciones analíticas simplificadas. Utilizando un dataset de 478 resultados experimentales y el algoritmo eXtreme Gradient Boosting (XGBoost), alcanzaron: Precisión global del 84% en el modelo XGBoost subyacente,

precisión del 78% en las ecuaciones analíticas derivadas, métricas balanceadas (precisión, recall, F1-score entre 76-80%) para ambos modos de falla y un modelo no sesgado con diferencias menores al 4.4% entre modos de falla.

### 3.1.2 Antecedentes nacionales

- a) Blossiers & Jacinto (2020), en su tesis "Análisis de fallas estructurales y comportamiento sísmico en las uniones viga-columna en pórticos de concreto armado", analizaron las fallas y el comportamiento sísmico de uniones viga-columna en pórticos de concreto armado mediante dos enfoques complementarios: análisis de fallas en estructuras reales dañadas por sismos y modelación numérica de pórticos idealizados. Se identificaron de patrones de falla: Falla por viga fuerte-columna débil y falla por compresión como mecanismos predominantes en uniones.
- b) Molina & Sicha (2021), en su tesis "Diseño estructural de viviendas de albañilería confinada mediante el uso de redes neuronales artificiales en distritos de Lima con perfil de suelo tipo S1", implementaron redes neuronales artificiales (RNA) para el diseño estructural de viviendas de albañilería confinada, demostrando que es posible automatizar procesos de diseño con un margen de error del 10% en comparación con métodos tradicionales. Molina & Sicha desarrollaron un modelo con arquitectura 4:10:26 que procesa 4 parámetros de entrada (geometría de edificación y muros) y genera 26 parámetros de salida (dimensiones y refuerzos de elementos estructurales), alcanzando un error de validación de 7.69% y máximo de 5.78% en pruebas específicas.
- c) Fernandez (2022), en su tesis "Uso de redes neuronales artificiales en el cálculo de la distorsión de entrepiso en edificaciones de albañilería confinada, Lima-2022", implementaron redes neuronales artificiales (RNA) para predecir distorsiones de entrepiso en edificaciones de albañilería confinada, alcanzando correlaciones del 96% en el eje X y 84% en el eje Y con respecto al método tradicional. El estudio desarrolló un modelo secuencial con arquitectura 5-20-20-10-5-2 utilizando TensorFlow, que mostró capacidad para optimizar tiempos de diseño estructural manteniendo precisiones elevadas.



d) Sanchez & Vidal (2021), en su tesis "Optimización de dimensiones de elementos estructurales mediante el uso de redes neuronales para la reducción de sobrecostos en edificios multifamiliares de 6 pisos ubicado en el distrito de Miraflores", estudiaron la capacidad de las redes neuronales artificiales (RNA) para optimizar dimensiones estructurales logrando una reducción del 10.11% en el uso de concreto ( $38.7 \text{ m}^3$ ), manteniendo el cumplimiento normativo con derivas máximas de 0.0070 (X) y 0.0069 (Y) bajo los límites de la Norma E.030. El modelo desarrollado, con arquitectura 4-25-25-10 y función de activación LOGSIG, alcanzó coeficientes de correlación de 0.97598 durante el entrenamiento y 0.98289 en validación interna.

## 3.2 Marco teórico

### 3.2.1 Machine Learning (ML)

El aprendizaje automático se define como el conjunto de métodos que permiten aprender automáticamente a partir de datos y hacer predicciones o tomar decisiones bajo incertidumbre (Murphy, 2012). Los métodos de ML pueden clasificarse en:

- Aprendizaje supervisado (Supervised Learning)
- Aprendizaje no supervisado (Unsupervised Learning)
- Aprendizaje por refuerzo (Reinforcement Learning)

Los métodos de aprendizaje supervisado, que son los más comunes en ingeniería estructural (Sun et al. 2021), utilizan datos etiquetados para mapear entradas con valores objetivo (salidas). Estos datos etiquetados se utilizan para entrenar un modelo predictivo.

La predicción de la capacidad a cortante en las uniones viga columna de concreto reforzado corresponde a un problema de regresión dentro de la categoría de algoritmos de ML supervisados, donde el objetivo es realizar un mapeo altamente no lineal entre las características de entrada y la variable de salida (resistencia a cortante).



Varios métodos de aprendizaje supervisado se han aplicado en ingeniería estructural como han dado a conocer Sun et al. (2021). Entre estos métodos, el aprendizaje por conjunto (Ensemble Learning) es una estrategia popular debido a su, eficiencia, precisión e Interpretabilidad como lo mencionaron Mangalathu et al. (2020). Los modelos de conjunto combinan modelos más débiles en esquemas iterativos en serie o en paralelo, corrigiendo los errores de modelos anteriores, para obtener un predictor más fuerte con menos sesgo y varianza. En esta investigación, se utilizarán tres modelos de aprendizaje de conjunto para establecer la mejor predicción de resistencia a cortante para las uniones viga columna de concreto reforzado:

#### a) Bosque Aleatorio (Random Forest)

El modelo de Random Forest (RF) se propuso como una forma de reducir la varianza de las estimaciones en los modelos Decisión Tree (DT). Según Murphy (2012) RF opera promediando los resultados de un conjunto de árboles seleccionados aleatoriamente que se ajustan a diferentes subconjuntos de los datos. Breiman (2001) indica que un modelo RF se entrena como un grupo de modelos DT independientes en paralelo, y cada uno de estos se convierte en un subconjunto aleatorio diferente del conjunto de entrenamiento. Esta técnica se llama bagging, y la estimación final para un conjunto de  $M$  árboles viene dada por:

$$f(x_i) = \frac{1}{M} \sum_{k=1}^M f_k(x_i)$$

donde

$x_i$        $i$ -ésima muestra en el conjunto de entrenamiento

$f_k$        $k$ -ésimo árbol

$M$       número total de árboles individuales utilizados por el modelo RF

Los modelos RF generalmente logran una buena precisión predictiva incluso para sistemas altamente no lineales.



## b) Adaptive Boosting - AdaBoost

Es un algoritmo que combina secuencial e iterativamente aprendices débiles, corrigiendo los errores de modelos anteriores, para obtener un predictor más fuerte. Según Sun et al. (2021) después de cada ronda de entrenamiento, AdaBoost aplica pesos mayores a los casos mal predichos y vuelve a entrenar a los aprendices para que la predicción final se base en la agregación de las predicciones ponderadas de rondas anteriores. Los modelos AdaBoost generan predictores que toman decisiones basadas en una variable, denominada stump. A partir de un conjunto de datos con  $n$  muestras,  $\mathcal{D} = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}$ , la función objetivo para un modelo AdaBoost se define por:

$$F(\mathbf{x}_i) = \sum_{t=1}^T G\{\alpha_t f_t(\mathbf{x}_i)\}$$

donde

$T$  número total de stumps

$f_t$  t-ésimo stump

$\alpha_t$  peso del t-ésimo stump

Para entrenar un modelo AdaBoost, el peso inicial del stump para cada muestra es uniforme  $w^{(i)} = \frac{1}{n}$ ,  $i = 1, 2, \dots, n$ ). Después del primer stump, el error se evalúa mediante:

$$r_j = \frac{\sum_{i=1}^n \mathbb{1}_{\hat{y}_j^{(i)} \neq y_j^{(i)}} w^{(i)}}{\sum_{i=1}^n w^{(i)}}$$

El error define la importancia del stump en la predicción final del modelo AdaBoost, que se calcula utilizando el factor de peso del stump:

$$\alpha_j = \eta \log \frac{1 - r_j}{r_j}$$

donde

$\eta$  tasa de aprendizaje (comúnmente tomada como 1)

Posteriormente, los pesos se actualizan, dando factores de peso mayores a los casos que fueron predichos pobremente. Luego, los pesos para el siguiente stump se actualizan de acuerdo con la siguiente ecuación:



$$w^{(i)} = \begin{cases} w^{(i)}, & \text{si } \hat{y}_j^{(i)} = y^{(i)} \\ w^{(i)} \exp(\alpha_j), & \text{si } \hat{y}_j^{(i)} \neq y^{(i)} \end{cases}$$

La actualización de los modelos AdaBoost continúa hasta que se alcanza el número deseado de predictores o cuando se encuentra un predictor perfecto. La predicción final se calcula como una agregación lineal de los modelos base ponderados.

### c) Extreme Gradient Boosting (XGBoost)

El modelo XGBoost entrena secuencialmente múltiples árboles de decisión utilizando técnicas de potenciación de gradiente (gradient boosting). En cada paso, se reducen los errores del modelo anterior (Feng et al. 2021a). Además, XGBoost utiliza una función de pérdida mejor regularizada, en comparación con otras implementaciones de técnicas de potenciación de gradiente, para restringir el sobreajuste (Esteghamati y Flint 2021). La predicción final en un modelo XGBoost se define por:

$$\hat{y}_i = \phi(\mathbf{x}_i) = \sum_{k=1}^M \alpha_k f_k(\mathbf{x}_i)$$

donde

$\phi(\cdot)$  aprendiz fuerte final

$f_k$  aprendiz débil

$M$  número total de aprendices débiles

$\alpha_k$  tasa de aprendizaje utilizada para evitar el sobreajuste.

La función de pérdida regularizada  $\mathcal{L}(\cdot)$  para un modelo XGBoost se define por:

$$\mathcal{L}(\phi) = \sum_i L(y_i, \hat{y}_i) + \sum_k \Omega(f_k)$$

Donde el primer término representa la pérdida de entrenamiento y el segundo término cuantifica la complejidad del modelo. En el proceso de entrenamiento para el modelo XGBoost, se utiliza un algoritmo voraz aproximado para encontrar el aprendiz o estructura de árbol  $f_t$  en cada paso  $t \leq M$  que minimice la siguiente función de pérdida:



$$f_t = \operatorname{argmin} \mathcal{L}(\phi)_\theta = \operatorname{argmin}_\theta \left[ \sum_{i=1}^n L(y_i, \phi_t(x_i)) + \sum_{k=1}^t \Omega(f_k) \right]$$

#### d) Explicaciones aditivas de Shapley (SHAP)

En la actualidad, los modelos de Machine Learning se emplean en dominios de alta responsabilidad donde la transparencia es crucial. La interpretabilidad se refiere a la capacidad de comprender y explicar las decisiones tomadas por un modelo de ML. Esta característica es particularmente importante en, aplicaciones médicas, de salud, sistemas financieros de riesgo, Ingeniería estructural y procesos de toma de decisiones críticas. Los métodos de interpretabilidad pueden clasificarse en:

- Métodos intrínsecos: Modelos naturalmente interpretables (árboles de decisión, modelos lineales).
- Métodos post-hoc: Técnicas que explican modelos complejos después del entrenamiento.
- Métodos específicos del modelo: Diseñados para arquitecturas particulares.
- Métodos agnósticos del modelo: Aplicables a cualquier tipo de modelo.

Los valores SHAP (SHapley Additive exPlanations) representan un método de interpretabilidad post-hoc y agnóstico del modelo que combina principios de la teoría de juegos cooperativos con explicaciones locales de modelos de ML. La teoría de juegos cooperativos fue desarrollada por Lloyd Shapley en 1953 para resolver el problema de distribución justa de ganancias entre jugadores en coaliciones. En el contexto de ML:

- Jugadores = Características del modelo
- Juego = Proceso de predicción



- Ganancia = Diferencia entre predicción real y promedio

Los valores SHAP aproximan localmente cualquier modelo complejo  $f$  mediante una función lineal  $g$  en el vecindario de cada instancia ( $\mathbf{x}$ ):

$$g(\mathbf{x}') = \phi_0 + \sum_{i=1}^k \phi_i x'_i$$

donde:

- $k$       Número total de características
- $\phi_0$     Valor esperado del modelo (predicción promedio)
- $\phi_i$     Contribución de la característica  $i$
- $\mathbf{x}'$     Vector binario de presencia de características

La propiedad de precisión local garantiza que la suma de las contribuciones de todas las características más el valor base reproduce exactamente la predicción del modelo original.

Es importante precisar que los valores obtenidos mediante el método SHAP (Shapley Additive exPlanations) no poseen unidades físicas ni representan coeficientes mecánicos directos asociados a los parámetros estructurales del modelo. A diferencia de los coeficientes de una regresión lineal que pueden interpretarse como variaciones cuantificables de la variable respuesta por unidad de cambio en un parámetro físico, los valores SHAP: no son constantes globales; no constituyen parámetros mecánicos calibrados; no equivalen a factores de resistencia; no representan contribuciones energéticas ni tensionales reales (parámetros físicos). Los valores SHAP expresan la contribución relativa de cada variable de entrada a la predicción específica generada por el modelo de ML.

#### e) Fórmula general de Shapley

La contribución  $\phi_i$  de cada característica se calcula como:

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} (f_{S \cup \{i\}}(\mathbf{x}_{S \cup \{i\}}) - f_S(\mathbf{x}_S))$$



Componentes de la fórmula:

$F$	Conjunto completo de características
$S$	Subconjunto (coalición) de características
$f_S$	Modelo entrenado solo con características en $S$
$ S $	Tamaño de la coalición $S$

La ecuación anterior representa:

El promedio ponderado de todas las posibles coaliciones

La diferencia marginal al añadir la característica  $i$

Los pesos que consideran el tamaño de las coaliciones

### 3.2.2 Modelos de resistencia al corte de la unión viga columna

Se han propuesto varios modelos para predecir la resistencia a cortante de las uniones viga-columna. Esta sección revisa las características principales de un subconjunto representativo de estos modelos y compara las resistencias calculadas con las resistencias medidas experimentalmente.

#### a) Modelo de Hwang y Lee

Hwang y Lee (1999) desarrollaron un modelo de puntal y tensor suavizado (Softened Strut-and-Tie Model, SSTM) diseñado para aplicarse tanto a nudos confinados como no confinados. Las características principales del modelo son:

- El puntal diagonal principal es el elemento estructural que transmite las cargas principales
- Los puntales secundarios, son los elementos que equilibran las fuerzas mediante, la armadura transversal en la viga y la armadura longitudinal distribuida en la columna

Para uniones con armadura transversal, se supone que la falla de la unión se inicia cuando, la armadura transversal alcanza su límite de fluencia. Hwang y

Lee extendieron el modelo a uniones no confinados interpretando que este caso es similar a tener, que los estribos que han entrado en fluencia y son ineficientes.

**b) Modelo de puntal y tensor de ángulo fijo de Parker y Bullman**

El modelo monotónico de puntal y tensor de ángulo fijo (SSTM) desarrollado por Parker y Bullman (1997) fue creado originalmente para vigas controladas por cortante y adaptado para definir la resistencia a cortante de nudos mediante la siguiente expresión:

$$V_f = \alpha v f_{cu} b_c h_c$$

En la ecuación,  $f_{cu}$  representa la resistencia del cubo de concreto, y  $v$  es un coeficiente de suavizado del puntal que varía con la resistencia a compresión del concreto y se calcula mediante las siguientes ecuaciones:

$$v = 0.56 - f_{cu}/310 \geq 0.40 \text{ MPa en [MPa]}$$

$$v = 0.56 - f_{cu}/44,950 \geq 0.40 \text{ psi en [psi]}$$

La capacidad del puntal se incluye mediante el factor  $\alpha$  que es igual a:

$$\alpha = \frac{1 - \delta \tan \theta_{crit}}{\tan \theta_{crit} + 1/\tan \theta_{crit}}$$

donde

$\delta$  depende del peralte efectivo de la viga

$d_b$  peralte efectivo de la columna

$d_c$  y del radio de dobléz de la barra de viga  $R$  anclada en el nudo y se calcula:

$$\delta = \frac{0.8}{d_c} (d_b - R)$$

$\tan \theta_{crit}$  representa la inclinación del puntal:

$$\tan \theta_{crit} = 1 - \frac{\delta}{2} \text{ para } \delta < 0.5$$

$$\tan \theta_{crit} = \frac{1}{2\delta} + \frac{(\delta^2 - 0.75)}{(\delta^3 + 2.5\delta)} \text{ para } \delta > 0.5$$



El desempeño del modelo Parker y Bullman cuando se aplica a los ensayos de una base de datos experimental, el modelo subestima significativamente la resistencia a cortante cíclico de nudos no confinados, con una relación entre resistencias experimental y calculada, el promedio (AVG) y el Coeficiente de Variación (COV) es:

$$VG = 2.0 \quad y \quad COV = 0.35$$

**c) Modelo de resistencia a cortante de nudos Tsonos**

El modelo de resistencia a cortante de nudos de Tsonos (2009) fue desarrollado basándose en relaciones tensión-deformación principales para paneles de hormigón armado, combinando mecanismos de puntal y de celosía. El mecanismo de celosía se considera ausente cuando el modelo se interpreta para nudos no armados. De acuerdo con el modelo, la resistencia a cortante de nudos no armados puede obtenerse resolviendo la siguiente expresión para  $V_j$ :

$$\frac{h_b V_j}{2b_1 h_c^2 f_c} \left( 1 + \sqrt{1 + \frac{4h_c}{h_b}} \right)^5 + \frac{5h_b V_j}{b_1 h_c^2 f_c} \left( \sqrt{1 + \frac{4h_c}{h_b}} - 1 \right) = 1$$

El modelo tiende a sobrestimar la resistencia a cortante. Los parámetros estadísticos de la relación entre resistencias experimental y calculada son:

$$AVG = 0.82 \quad y \quad COV = 0.28$$

**d) Modelo empírico de Sarsam y Phipps**

El modelo empírico desarrollado por Sarsam y Phipps (1985) se derivó basándose en la resistencia a cortante de vigas críticas en cortante con baja relación luz de cortante-peralte. La resistencia a cortante se expresa como:

$$V = 5.47(f'_c \rho_c)^{0.33} \left( \frac{d_c}{d_b} \right)^{1.33} (1 + 0.29P/A_g)^{0.5} b_c d_c \text{ en [MPa]}$$

$$V = 28.3(f'_c \rho_c)^{0.33} \left( \frac{d_c}{d_b} \right)^{1.33} (1 + 0.29P/A_g)^{0.5} b_c d_c \text{ en [psi]}$$



donde:

$\rho_c$	Cuantía de armadura de la capa de acero más alejada de la fibra de compresión máxima en la columna
$d_c$	Peralte efectivo de esa capa
$d_b$	Peralte efectivo de la viga (mm)
$P$	Carga axial de la columna (N)
$A_g$	Área bruta de la sección transversal de la columna (mm <sup>2</sup> )
$b_c$	Ancho de la columna (mm)

Los coeficientes empíricos se derivaron utilizando una base de datos de ensayos monotónicos de nudos viga-columna. El modelo tiende a subestimar la resistencia a cortante. Los parámetros estadísticos de la relación entre resistencias experimental y calculada son:

$$AVG = 1.42 \quad y \quad COV = 0.32$$

**e) Modelo de puntal y tensor de ángulo fijo Vollum y Newman**

Vollum y Newman (1999) presentaron un modelo empírico monotónico de puntal y tensor de ángulo fijo para evaluar la resistencia a cortante. El modelo no incluye un método para evaluar explícitamente las dimensiones y capacidad del puntal o el modo de falla, ya que especularon sobre la alta imprecisión de los modelos con dimensiones explícitas de puntal. Los únicos dos parámetros de configuración del modelo son, la relación de aspecto del nudo y el detalle de las barras de viga dentro del nudo, el modelo no incluye el efecto de la carga axial. Las ecuaciones del modelo, para nudos no confinados, son:

$$V_j = 0.624\beta(1 + 0.555(2 - h_b/h_c))b_jh_c\sqrt{f'_c} \text{ en [MPa]}$$

$$V_j = 7.52\beta(1 + 0.555(2 - h_b/h_c))b_jh_c\sqrt{f'_c} \text{ en [psi]}$$

$$V_j < 0.97b_jh_c\sqrt{f'_c}(1 + 0.555(2 - h_b/h_c)) < 1.33b_jh_c\sqrt{f'_c} \text{ en [MPa]}$$

$$V_j < 11.7b_jh_c\sqrt{f'_c}(1 + 0.555(2 - h_b/h_c)) < 16b_jh_c\sqrt{f'_c} \text{ en [psi]}$$



donde

$\beta$  es un factor que considera los detalles de las barras de viga dentro del nudo, tomado igual a 1.0 para barras dobladas hacia el interior del nudo.

Los límites superiores impuestos a la resistencia a cortante del nudo se establecieron debido a las limitaciones de la base de datos de ensayos que Vollum y Newman utilizaron para calibrar el modelo. Los parámetros estadísticos de la relación entre resistencias experimental y calculada son:

$$AVG = 0.97 \quad y \quad COV = 0.1$$

**f) Modelo empírico para nudos exteriores de Bakir y Boduroğlu**

El modelo empírico de Bakir y Boduroğlu (2002) para la resistencia a cortante de nudos exteriores se expresa en la ecuación siguiente. El modelo se basa en un estudio paramétrico para cuantificar el efecto de diferentes parámetros en la resistencia del nudo, como la cuantía de armadura de la viga, la relación de aspecto del nudo y los detalles de anclaje de la armadura de la viga.

El efecto de los parámetros se calibró independiente y colectivamente basándose en resultados de ensayos de una base de datos de nudos exteriores sometidos a carga monotónica. El modelo no considera explícitamente el efecto de la carga axial de la columna sobre la resistencia a cortante del nudo.

$$V_j = 0.71\beta\gamma(100\rho)^{0.4289} \left(\frac{h_b}{h_c}\right)^{-0.61} \left(\frac{b_c + b_b}{2}\right) h_c \sqrt{f'_c} \text{ en [MPa]}$$

$$V_j = 8.56\beta\gamma(100\rho)^{0.4289} \left(\frac{h_b}{h_c}\right)^{-0.61} \left(\frac{b_c + b_b}{2}\right) h_c \sqrt{f'_c} \text{ en [psi]}$$

donde:

$\beta = 1$  para nudos con armadura de viga anclada mediante gancho estándar

$\gamma = 1$  para barras no inclinadas en el nudo

$\rho_c$  es la cuantía de armadura de la viga



Los parámetros estadísticos de la relación entre resistencias experimental y calculada son:

$$AVG = 1.29 \quad \text{y} \quad COV = 0.17$$

Lo que indica una subestimación moderada de la resistencia del nudo.

**g) Modelo bayesiano para resistencia a cortante de LaFave y Kim**

Kim y LaFave (2009, 2012) y LaFave y Kim (2011) utilizaron un enfoque bayesiano para desarrollar un modelo de resistencia a cortante de nudos considerando una base de datos de ensayos. La ecuación resultante de resistencia a cortante de nudos, interpretada para nudos viga-columna exteriores y de esquina sin armadura transversal, es:

$$V_j = \alpha_t \beta_t \eta_t \lambda_t (0.0128)^{0.15} (BI)^{0.30} (f'_c)^{0.75} b_j h_c \text{ en [MPa]}$$

$$V_j = 41.8 \alpha_t \beta_t \eta_t \lambda_t (0.0128)^{0.15} (BI)^{0.30} (f'_c)^{0.75} b_j h_c \text{ en [psi]}$$

donde:

$\alpha_t$       Parámetro que describe la geometría en planta, tomado como 0.7 para conexiones exteriores.

$\lambda_t$       Factor de calibración, tomado como 1.31

$\beta_t$       Parámetro para geometría fuera de planta

- = 1.0 para subensamblajes con 0 o 1 vigas transversales
- = 1.18 para subensamblajes con 2 vigas transversales

$\eta_i$       Describe la excentricidad del nudo

- = 1.0 sin excentricidad del nudo
- = 0.0139: Índice de armadura de nudo virtual usado en nudos no confinados

$BI$       índice de armadura de viga definido como  $\rho f_y / f'_c$ .

La base de datos utilizada para construir este modelo tenía solo tres nudos exteriores no confinados con falla tipo J.



Los parámetros estadísticos de la relación entre resistencias experimental y calculada son:

$$AVG = 1.17 \quad \text{y} \quad COV = 0.18$$

Lo que indica una buena estimación de la resistencia del nudo con una dispersión relativamente moderada.

### 3.3 Marco conceptual

- a) **Métodos de ensamble (Ensemble Learning):** Estrategias que combinan múltiples modelos para mejorar la precisión y reducir la varianza. Estos métodos, como bagging, boosting o stacking, permiten obtener modelos más confiables capaces de manejar la variabilidad inherente en los ensayos de materiales y componentes estructurales.
- b) **XGBoost:** Algoritmo basado en gradient boosting que combina múltiples árboles de decisión para obtener predicciones altamente precisas y robustas. Es uno de los modelos más eficientes en ingeniería estructural debido a su capacidad para capturar interacciones complejas entre variables.
- c) **Random Forest:** Conjunto de árboles de decisión entrenados en paralelo que mejora la estabilidad y reduce el sobreajuste.
- d) **Gradient Boosting:** Modelo secuencial que optimiza el error del modelo previo mediante árboles más pequeños y especializados.
- e) **Hiperparámetros:** Configuraciones internas del modelo que controlan su complejidad, como profundidad de los árboles, número de estimadores, tasa de aprendizaje (Learning rate) o regularización. Su ajuste adecuado mejora notablemente la precisión del modelo.
- f) **Validación cruzada:** Método de evaluación que reparte los datos en varios subconjuntos para entrenar y validar el modelo múltiples veces. Permite obtener métricas más estables y reduce el riesgo de sobreajuste.
- g) **Sobreajuste (overfitting):** Fenómeno en el que un modelo aprende demasiado bien los datos de entrenamiento, perdiendo capacidad para generalizar en datos nuevos. Es

especialmente relevante cuando se utilizan bases de datos experimentales pequeñas o con alta variabilidad.

- h) Métricas de desempeño:** Indicadores que permiten cuantificar la precisión del modelo.
- i) Coeficiente de determinación ( $R^2$ ):** El coeficiente de determinación mide la proporción de la variabilidad de la variable objetivo que es explicada por el modelo. Un valor cercano a 1 indica que el modelo presenta un ajuste adecuado y tiene alta capacidad predictiva, mientras que valores próximos a 0 evidencian un desempeño deficiente. Es una de las métricas más utilizadas en problemas de regresión estructural debido a su fácil interpretación.
- j) Error cuadrático medio (MSE):** Representa el promedio de los errores elevados al cuadrado entre los valores estimados y los reales. Esta métrica penaliza con mayor intensidad los errores grandes, lo cual es relevante en ingeniería estructural, donde una subestimación considerable puede comprometer la seguridad del diseño.
- k) Raíz del error cuadrático medio (RMSE):** Indica el error promedio en las mismas unidades de la variable a predecir. Es una de las métricas más apropiadas para evaluar modelos que predicen variables físicas, puesto que permite interpretar la magnitud del error de cada predicción.
- l) Error absoluto medio (MAE):** Cuantifica la magnitud promedio del error sin penalizar en exceso los valores atípicos. A diferencia del RMSE, cada error tiene el mismo peso, lo que lo convierte en un indicador confiable cuando los datos presentan dispersión moderada o presencia de mediciones experimentales con variabilidad inherente.
- m) Error porcentual absoluto medio (MAPE):** Expresa el error en términos porcentuales respecto a los valores reales, permitiendo evaluar qué tan exactas son las predicciones en relación con la magnitud observada. Es útil cuando se comparan modelos en diferentes escalas, aunque debe emplearse con cautela si existen valores cercanos a cero.

- n) **Explicabilidad del modelo (Explainable AI):** Conjunto de metodologías que permiten comprender cómo un modelo complejo genera sus predicciones. Es fundamental en ingeniería estructural para garantizar transparencia y aceptación de modelos basados en ML.
  
- o) **Valores SHAP:** Técnica basada en teoría de juegos cooperativos que asigna a cada variable una contribución cuantitativa a la predicción de un modelo. Cada predicción puede descomponerse en aportes positivos o negativos de sus variables.
  
- p) **Importancia de características:** Medida que identifica qué variables influyen más en la predicción. Por ejemplo, cuantía de refuerzo transversal, resistencia del concreto o geometría del nodo.



## **CAPÍTULO IV METODOLOGÍA**

### **4.1 Tipo y nivel de investigación**

#### **4.1.1 Tipo de investigación**

La investigación fue del tipo aplicada, ya que busca resolver un problema específico de la ingeniería estructural: la predicción precisa de la resistencia al corte en la unión viga-columna mediante el uso de técnicas de Machine Learning. Según el nivel de investigación corresponde al descriptivo, pues busca describir a los modelos de Machine Learning mediante sus métricas de desempeño una vez entrenado el modelo correspondiente. El enfoque metodológico fue cuantitativo, se realiza un análisis estadístico y algoritmos de aprendizaje automático para el procesamiento sistemático de datos numéricos.

#### **4.1.2 Nivel de investigación**

El nivel de la investigación fue descriptivo, pues busca describir a los modelos de Machine Learning mediante sus métricas de desempeño una vez entrenado el modelo correspondiente. En la presente investigación, no solo se busca predecir la resistencia al corte, sino también comprender e interpretar las relaciones entre las variables que influyen en este fenómeno físico. A través de técnicas de explicabilidad de modelos, se determinó el peso e influencia de cada variable independiente en la resistencia, permitiendo generar conocimiento sobre los mecanismos de falla y los factores más relevantes en el comportamiento estructural.

### **4.2 Diseño de la investigación**

El diseño de investigación corresponde a un diseño no experimental, transversal y de tipo aplicativo-descriptivo. Es no experimental porque se basa en la observación y análisis de datos existentes provenientes de literatura científica, sin manipulación directa de variables. Es transversal ya que los datos recopilados corresponden a un período temporal específico desde 1967 al 2020.



### **4.3 Descripción ética de la investigación**

La presente investigación se desarrolló bajo los principios éticos fundamentales que rigen la investigación científica, garantizando en todo momento la integridad, confiabilidad y transparencia del proceso investigativo.

En cuanto al uso de datos, se respetó rigurosamente los derechos de propiedad intelectual y las normativas de citación. Todos los datos experimentales utilizados, provenientes de literatura científica publicada, fueron debidamente referenciados, reconociendo el trabajo original de los investigadores. No se utilizará información de fuentes no autorizadas o que requieran permisos especiales sin la debida autorización.

En el ámbito metodológico, se mantuvo una estricta honestidad en el tratamiento y análisis de datos. No se manipularán, alterarán o omitirán resultados que puedan afectar la validez de las conclusiones. Se implemento protocolos para garantizar la reproducibilidad de la investigación, documentando detalladamente todos los procesos, parámetros y algoritmos utilizados en el desarrollo de los modelos de Machine Learning.

En la fase de modelamiento, se evito sesgos en la selección y preparación de datos, aplicando técnicas de validación cruzada y división aleatoria para asegurar la representatividad de los resultados. Los modelos fueron evaluados con métricas objetivas y estandarizadas, reportando tanto los aciertos como las limitaciones de manera transparente.

En la discusión de resultados, se aseguró la claridad y precisión en la comunicación de hallazgos, evitando afirmaciones exageradas o especulativas sobre las capacidades predictivas de los modelos desarrollados. Se reconoció las limitaciones del estudio y se realizó adecuadamente el trabajo previo en la materia.

### **4.4 Población y muestra**

#### **4.4.1 Población**

La población de este estudio estuvo constituida por todos los ensayos experimentales de uniones viga-columna de concreto reforzado reportados en la literatura científica internacional, que cumplan con los criterios de disponibilidad y completitud de información necesaria para el análisis de resistencia al corte. Esta



población abarco investigaciones desarrolladas entre 1967 y 2020 en diversos centros de investigación a nivel global, representando diferentes configuraciones geométricas, propiedades de materiales y condiciones de carga. En total son 596 ensayos experimentales de uniones viga-columna que conforman la población de la presente tesis.

#### 4.4.2 Muestra

La muestra se seleccionó mediante un muestreo intencionado (no probabilístico), priorizando la disponibilidad de información.

La muestra final para la investigación estuvo conformada por 596 registros experimentales, obtenidos mediante una recopilación exhaustiva de estudios publicados que cumplieron con los criterios establecidos para esta investigación. Cada registro represento el comportamiento a cortante de una unión viga-columna sometida a carga cíclica o monotónica, se aclara que la cantidad de muestra es similar a la población en vista que el desarrollo de modelos Machine Learning, demanda la mayor cantidad de datos posibles para evitar el sobreajuste (overfitting) y obtener mejores resultados de predicción de la resistencia al corte en la unión viga-columna.

La muestra considero variables independientes clave, entre las que se incluyen: tipo de unión, resistencia a compresión del concreto ( $f'_c$ ), cuantía y esfuerzo de fluencia del refuerzo transversal en la zona de la unión ( $\rho_{jt}$ ,  $f_{yjt}$ ), cuantía y esfuerzo de fluencia del refuerzo longitudinal de la viga ( $\rho_b$ ,  $f_{yb}$ ), dimensiones de la viga ( $h_b$ ,  $b_b$ ), cuantía y esfuerzo de fluencia del refuerzo longitudinal de la columna ( $\rho_c$ ,  $f_{yc}$ ), dimensiones de la columna ( $h_c$ ,  $b_c$ ) y el ratio de carga axial (ALF). La variable dependiente es la resistencia a corte experimental de la unión viga-columna ( $\tau_{exp}$ ).

#### 4.5 Procedimiento

La presente investigación se desarrolló en las siguientes etapas:

- **Recolección y compilación de datos experimentales:** El procedimiento inicio con la construcción de una base de datos experimental. Para lo cual se realizó una revisión sistemática de la literatura con la finalidad de recopilar entre 500 y 800 ensayos experimentales de uniones viga-columna que reporten la resistencia al corte. Los datos



a compilar incluyeron variables geométricas (dimensiones de la viga y columna, refuerzo transversal y longitudinal), propiedades de los materiales (resistencia del concreto  $f'_c$ , esfuerzo de fluencia del acero  $f_y, f_{yt}$ ), detalles de refuerzo (cuantías  $\rho_{jt}$ ,  $\rho_b$  y  $\rho_c$ ) y las condiciones de carga (carga axial), junto con la resistencia al corte experimental medida ( $\tau_{exp}$ ).

- **Preprocesamiento y análisis exploratorio:** Una vez compilados, los datos fueron sometidos a un riguroso preprocesamiento. Esto implicó la identificación y tratamiento de valores atípicos, el manejo de datos faltantes y la normalización de las variables. Posteriormente, se realizó un análisis exploratorio utilizando histogramas, diagramas de caja y matrices de correlación para comprender la distribución, relaciones y potenciales redundancias entre las variables en el conjunto de datos.
- **Ingeniería de características:** En esta etapa crítica, se seleccionaron las variables de entrada (características) más relevantes. La selección se basó en tres pilares: la revisión de modelos mecánicos existentes (como ACI 318 o Eurocode 2), un análisis de correlación estadística para identificar las variables que más influyen en la resistencia al corte, y la consideración de criterios de ingeniería estructural. Se crearon características adimensionales, para reducir la no linealidad.
- **Entrenamiento de múltiples modelos de Machine Learning:** El conjunto de datos se dividió, utilizando el 80% para entrenamiento y el 20% para prueba. Se procedió a entrenar y comparar 15 modelos de ML diferentes, cubriendo una amplia gama de algoritmos. Estos incluyeron métodos de ensamble (XGBoost, Random Forest, Gradient Boosting, CatBoost y LightGBM), redes neuronales (MLP, ANN profundas), Máquinas de Vectores de Soporte (SVR con distintos kernels).
- **Evaluación y selección del mejor modelo:** El desempeño de los 15 modelos se evaluó utilizando el conjunto de prueba y métricas robustas. Estas métricas incluyeron el coeficiente de determinación ( $R^2$ ), el error cuadrático medio (RMSE), el error absoluto medio (MAE) y el índice D10% (que mide el porcentaje de predicciones con error inferior al 10%). Para asegurar la robustez, se empleó una validación cruzada de 5 folds. Los modelos fueron rankeados según su desempeño, y los 5 mejores pasaron a una fase de análisis detallado para seleccionar el modelo óptimo.

- **Optimización de hiperparámetros:** El modelo seleccionado se sometió a un proceso de optimización para maximizar su capacidad predictiva. Utilizando la técnica de Búsqueda en Cuadrícula (Grid Search) acoplada a una validación cruzada de 5 folds, se exploró de manera iterativa y sistemática distintas combinaciones de los hiperparámetros específicos del modelo (como el número de estimadores, la tasa de aprendizaje o la profundidad máxima) hasta encontrar la combinación de mejor rendimiento.
- **Explicabilidad del modelo:** Para superar la caja negra de los modelos de ML y ganar confianza en sus predicciones, se aplicó la técnica SHAP (SHapley Additive exPlanations). Este análisis proporciona una explicación global, mostrando la importancia promedio de cada variable en el modelo, y una explicación local, permitiendo entender cómo contribuyó cada variable en una predicción individual específica, lo que es crucial para la validación ingenieril.
- **Validación y comparación final:** El modelo optimizado y explicado ha sido validado de manera definitiva con el conjunto de prueba (el 20% de datos no vistos durante el entrenamiento).

#### 4.6 Técnica e instrumentos

La técnica que se utilizó fue la observación y el instrumento la ficha de observación

##### 4.6.1 Técnicas de recolección de datos

- **Revisión sistemática de la literatura:** Se aplicó la técnica de revisión sistemática para recopilar datos experimentales de investigaciones previas sobre resistencia al corte en uniones viga-columna. Esta técnica incluye la búsqueda en bases de datos científicas, filtrado por criterios de calidad y extracción metódica de datos.
- **Análisis documental:** Se examinaron normas técnicas internacionales (ACI 318, Eurocode 2) y publicaciones especializadas para identificar las variables más relevantes en el comportamiento de uniones viga-columna sometidas a cortante.



- **Recolección de datos experimentales:** Se implementará un protocolo estandarizado para la extracción de datos de artículos científicos, incluyendo variables geométricas, propiedades de materiales, condiciones de carga y resultados experimentales de resistencia al corte.
- **Validación por expertos:** Técnica cualitativa que involucra la consulta a ingenieros estructurales especializados para validar la selección de variables y la interpretación de los resultados obtenidos por los modelos de Machine Learning.

#### 4.6.2 Instrumentos

Para el desarrollo de la presente investigación se emplearán los siguientes instrumentos:

- **Python:** Lenguaje de programación principal para la implementación de los 15 modelos de Machine Learning. Se utilizarán librerías especializadas como Scikit-learn para modelos tradicionales, para algoritmos de ensamble Learning, TensorFlow y Keras para redes neuronales, y Pandas para el procesamiento de datos.
- **Jupyter Notebooks:** Plataforma interactiva para el desarrollo y documentación del código, permitiendo la ejecución paso a paso de los algoritmos y el análisis inmediato de los resultados.
- **Google Colab Pro:** Plataforma en la nube para el procesamiento intensivo de datos y entrenamiento de modelos complejos, proporcionando acceso a GPUs y TPUs para acelerar los tiempos de computación.
- **SHAP (SHapley Additive exPlanations):** Biblioteca especializada para el análisis de explicabilidad de modelos de Machine Learning, permitiendo interpretar las predicciones y determinar la importancia de cada variable en los resultados.
- **Git y GitHub:** Sistema de control de versiones para la gestión del código fuente, colaboración en el desarrollo de algoritmos y documentación del proceso de investigación.



## CAPÍTULO V

### RESULTADOS Y DISCUSIONES

#### 5.1 Análisis de resultados

##### 5.1.1 Conjunto de datos y selección de características

Antes de entrenar los modelos, se extraen las características importantes (variables de entrada) y se eliminan las irrelevantes. La selección de características se realizó utilizando las siguientes consideraciones: (1) ecuaciones de diseño previas y modelos basados en la mecánica, (2) resultados del análisis de correlación entre las variables del conjunto de datos. Para la primera consideración, se utilizaron los resultados de estudios anteriores (Tsonos 2009; Sarsam y Phipps 1985; Vollum y Newman 1999; Bakir y Boduroğlu 2002; Hassan y Moehle 2018) para identificar las características importantes. La correlación entre estas características se utilizó para determinar la presencia de redundancia. Además, la correlación de estos grupos de características con la salida se utilizó para determinar cuáles de ellas podían descartarse. La correlación entre las características seleccionadas y la salida se presenta en la Figura 1, Figura 2 y Figura 3. La resistencia a cortante  $\tau_{exp}$  se consideró como la variable de salida. La información estadística de las características finales se presenta en la Tabla 2, Tabla 3 y Tabla 4.

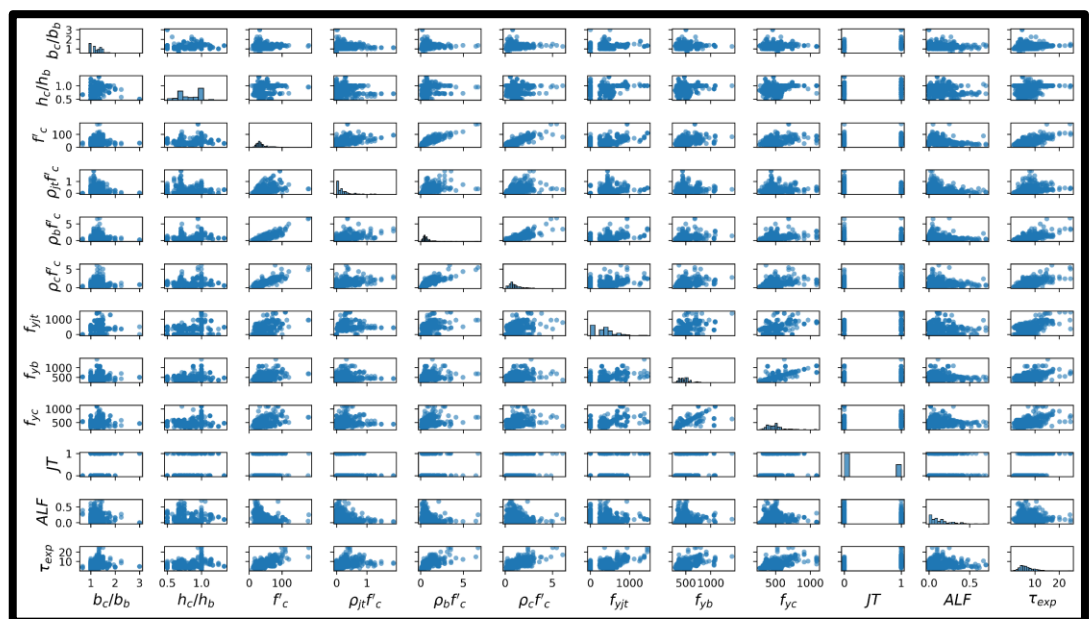


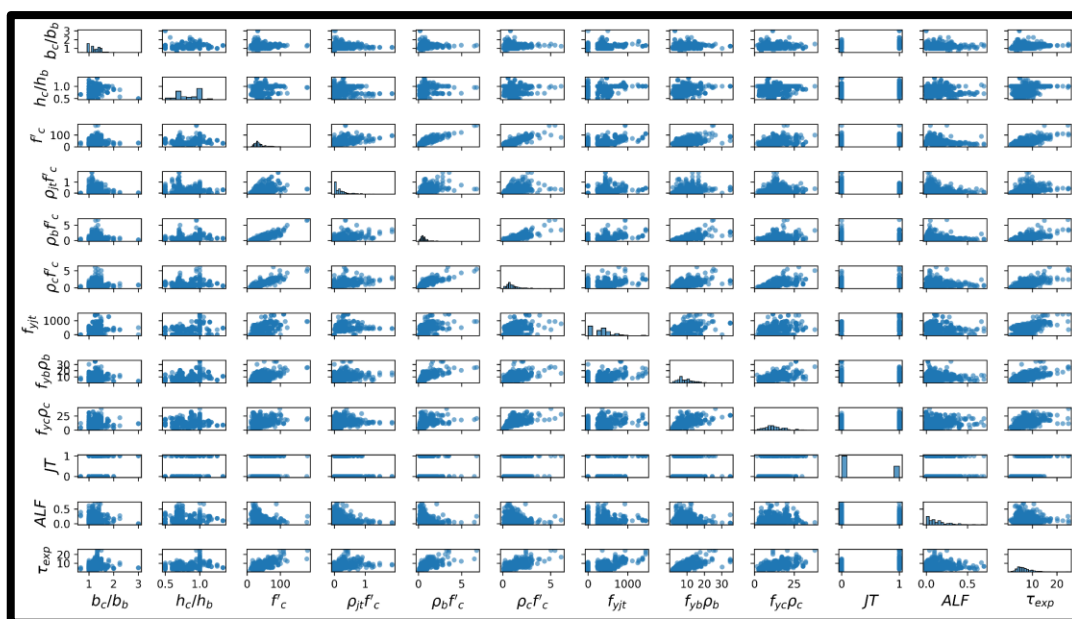
Figura 1 — Gráfico de dispersión de las características finales del dataset 1.



**Tabla 2 — Información estadística de los parámetros del dataset 1.**

Categoría	Variable	Unidad	Min.	Max.	Mean	St.D	Tipo
Dimensiones geométricas	$b_c/b_b$	-	0.67	3.00	1.25	0.24	Input
	$h_c/h_b$	-	0.50	1.33	0.84	0.17	Input
Propiedades del concreto	$f'_c$	MPa	8.30	182.00	39.79	21.06	Input
Índices de refuerzo	$\rho_{jt}f'_c$	MPa %	0.00	1.88	0.21	0.27	Input
	$\rho_b f'_c$	MPa %	0.06	6.73	0.78	0.72	Input
	$\rho_c f'_c$	MPa %	0.08	6.10	1.07	0.77	Input
Resistencia del acero	$f_{yjt}$	MPa	0.00	1452.00	339.14	289.74	Input
	$f_{yb}$	MPa	286.00	1429.00	498.68	144.41	Input
	$f_{yc}$	MPa	274.00	1092.00	490.98	126.42	Input
Clasificación	$JT$	-	0.00	1.00	0.34	0.48	Input
Carga	$ALF$	-	0.00	0.70	0.13	0.13	Input
Resistencia al corte	$\tau_{exp}$	MPa	1.20	24.70	6.95	3.47	Output

NOTA  
Min. — Mínimo; Max. — Máximo; Mean. — Mediana y St.D. — Desviación estándar.



**Figura 2 — Gráfico de dispersión de las características finales del dataset 2.**

**Tabla 3 — Información estadística de los parámetros del dataset 2.**

Categoría	Variable	Unidad	Min.	Max.	Mean	St.D	Tipo
Dimensiones geométricas	$b_c/b_b$	-	0.67	3.00	1.25	0.24	Input
	$h_c/h_b$	-	0.50	1.33	0.84	0.17	Input
Propiedades del concreto	$f'_c$	MPa	8.30	182.00	39.79	21.06	Input
Índices de refuerzo	$\rho_{jt}f'_c$	MPa-%	0.00	1.88	0.21	0.27	Input
	$\rho_b f'_c$	MPa-%	0.06	6.73	0.78	0.72	Input
	$\rho_c f'_c$	MPa-%	0.08	6.10	1.07	0.77	Input
Resistencia del acero	$f_{yjt}$	MPa	0.00	1452.00	339.14	289.74	Input



	$f_{yb}\rho_b$	MPa	1.67	34.91	9.25	4.97	Input
	$f_{yc}\rho_c$	MPa	1.62	38.10	12.88	6.12	Input
Clasificación	$JT$	-	0.00	1.00	0.34	0.48	Input
Carga	$ALF$	-	0.00	0.70	0.13	0.13	Input
Resistencia al corte	$\tau_{exp}$	MPa	1.20	24.70	6.95	3.47	Output

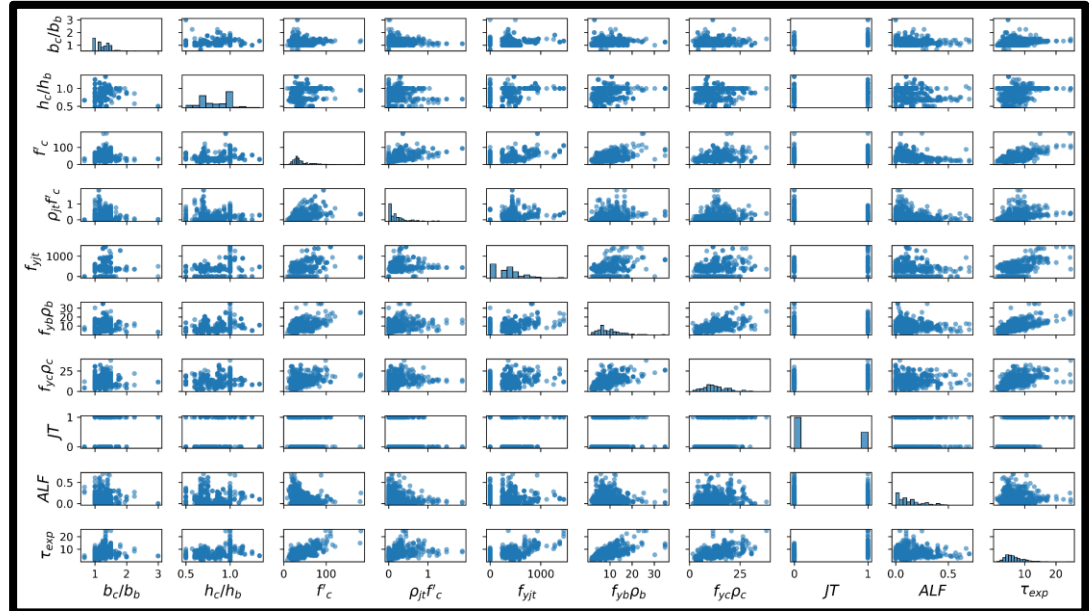


Figura 3 — Gráfico de dispersión de las características finales del dataset 3.

Tabla 4 — Información estadística de los parámetros del dataset 3.

Categoría	Variable	Unidad	Min.	Max.	Mean	St.D	Tipo
Dimensiones geométricas	$b_c/b_b$	-	0.67	3.00	1.25	0.24	Input
	$h_c/h_b$	-	0.50	1.33	0.84	0.17	Input
Propiedades del concreto	$f'_c$	MPa	8.30	182.00	39.79	21.06	Input
Índices de refuerzo	$\rho_{jt}f'_c$	MPa·%	0.00	1.88	0.21	0.27	Input
Resistencia del acero	$f_{yjt}$	MPa	0.00	1452.00	339.14	289.74	Input
	$f_{yb}\rho_b$	MPa	1.67	34.91	9.25	4.97	Input
	$f_{yc}\rho_c$	MPa	1.62	38.10	12.88	6.12	Input
Clasificación	$JT$	-	0.00	1.00	0.34	0.48	Input
Carga	$ALF$	-	0.00	0.70	0.13	0.13	Input
Resistencia al corte	$\tau_{exp}$	MPa	1.20	24.70	6.95	3.47	Output

Las variables de entrada seleccionadas para el dataset 1 se pueden agrupar en las siguientes categorías:

- **Geometría de la unión:** Relación ancho columna-viga  $b_c/b_b$  y relación altura columna-viga  $h_c/h_b$ .
- **Propiedad del concreto:** Resistencia a compresión  $f'_c$ .



- **Índices de refuerzo:** Producto de la cuantía de armadura por la resistencia a compresión del concreto para la unión  $\rho_{jt}f'_c$ , la viga  $\rho_b f'_c$  y la columna  $\rho_c f'_c$ .
- **Resistencia del acero:** Límite elástico del acero en la junta  $f_{yjt}$ , en la viga  $f_{yb}$  y en la columna  $f_{yc}$ .
- **Clasificación y carga:** Tipo de unión JT y Factor de Carga Axial ALF.

El dataset 2 representa una variación en la formulación de las características de entrada, manteniendo el mismo conjunto de datos experimentales base. Esta variante se diseñó para evaluar la influencia de diferentes combinaciones de parámetros en el desempeño predictivo del modelo.

Las principales modificaciones con respecto al dataset 1 se encuentran en la categoría de propiedades del acero. En lugar de utilizar la resistencia del acero de forma aislada para la viga y la columna, se introdujeron parámetros compuestos que capturan la contribución combinada del acero y su cuantía:

- Se reemplazó  $f_{yb}$  por el producto  $f_{yb}\rho_b$ .
- Se reemplazó  $f_{yc}$  por el producto  $f_{yc}\rho_c$ .

Esta formulación busca representar de manera más directa la fuerza axial aportada por el refuerzo longitudinal en los elementos. Las variables restantes (geométricas, del hormigón, de la junta y de clasificación) se mantienen idénticas a las del Dataset 1. La salida objetivo sigue siendo la tensión de corte experimental  $\tau_{exp}$ .

El dataset 3 constituye una configuración de entrada más simplificada, derivada de una hipótesis de ingeniería que prioriza los parámetros considerados más influyentes en la resistencia al corte de uniones. Este dataset se genera eliminando selectivamente ciertos índices de refuerzo del conjunto 2.

Las características específicas eliminadas son los índices compuestos para el hormigón de la viga y la columna  $\rho_b f'_c$  y  $\rho_c f'_c$ . La justificación de esta simplificación radica en evaluar si la información contenida en los productos  $f_{yb}\rho_b$  y  $f_{yc}\rho_c$  (ya presentes) y en el índice principal de la unión  $\rho_{jt}f'_c$  es suficiente para

lograr una precisión predictiva comparable. Por lo tanto, el dataset 3 está compuesto por:

- Geometría:  $b_c/b_b$ ,  $h_c/h_b$ .
- Concreto:  $f'_c$ .
- Refuerzo de la unión:  $\rho_{jt}f'_c$ .
- Acero (parámetros compuestos):  $f_{yjt}$ ,  $f_{yb}\rho_b$ ,  $f_{yc}\rho_c$ .
- Clasificación y carga: JT, ALF.

El objetivo de esta configuración es desarrollar un modelo potencialmente más eficiente y con menor riesgo de sobreajuste, manteniendo la misma variable de salida  $\tau_{exp}$ . La aplicabilidad del modelo entrenado con este dataset estará, como en los casos anteriores, restringida al rango de datos utilizados en su entrenamiento, cuyos límites se especifican en su correspondiente tabla de estadística descriptiva.

Los resultados del análisis de coeficientes de correlación para el dataset 1, 2 y 3 se presentan en la Figura 4 mediante un mapa de calor, que constituye una representación gráfica de la matriz de correlación. Los coeficientes de correlación de Pearson varían en un rango de +1 a -1, donde +1 indica una correlación positiva perfecta (directa) y -1 una correlación negativa perfecta (inversa). El mapa de calor utiliza una escala de color correspondiente al rango de valores observados en este estudio, donde un color más oscuro indica una correlación más fuerte. Por ejemplo, la celda correspondiente a la relación entre la resistencia a compresión del concreto  $f'_c$  y la resistencia al corte experimental  $\tau_{exp}$  muestra un coeficiente de 0.67, lo que indica una correlación positiva moderada del 67%.

Las celdas de color más oscuro en la última fila de la matriz permiten identificar rápidamente qué variables de entrada presentan las correlaciones más fuertes con la variable objetivo  $\tau_{exp}$ . Este análisis preliminar valida la selección de predictores y proporciona información sobre qué factores pueden tener mayor peso en la capacidad predictiva del modelo.



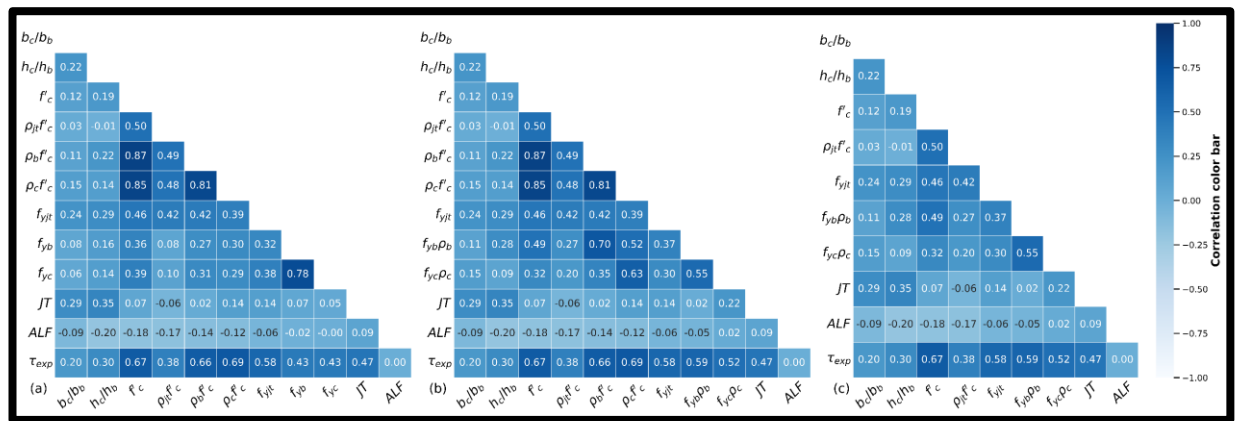


Figura 4 — Matriz de coeficientes de correlación para el dataset (a) 1, (b) 2 y (c) 3.

### 5.1.2 Entrenamiento y selección del modelo

Los datos se dividen en un conjunto de entrenamiento (80% del total de datos) y un conjunto de prueba (20% del total de datos). El conjunto de prueba se utiliza posteriormente para evaluar el rendimiento del modelo predictivo final. Esta proporción de división de datos se determinó después de una exploración inicial de su impacto en el rendimiento general de los modelos principalmente en términos del valor medio de  $R^2$  durante la validación cruzada CV.

El entrenamiento de los modelos se llevó a cabo utilizando la técnica de validación cruzada K -fold, que se utiliza comúnmente para reducir el sesgo, la varianza y el sobreajuste de los modelos de ML (Sun et al. 2021). Este método consiste en dividir aleatoriamente el conjunto de entrenamiento en K subconjuntos diferentes llamados folds. Luego, el modelo se entrena y evalúa K veces (es decir, seleccionando un subconjunto diferente cada vez), lo que da como resultado K puntuaciones para cada modelo. Esta técnica de validación cruzada produce una estimación del rendimiento del modelo, así como una medida de la precisión de esa estimación.

#### 5.1.2.1 Resultados para los modelos de Ensemble Learning

La Tabla 5 resume los valores medios y desviaciones estándar obtenidos durante la validación cruzada de 10 folds para los seis modelos de Ensemble Learning evaluados con el dataset 1. Las métricas consideradas ( $R^2$ , RMSE, MARD y  $D_{10\%}$ ) permiten caracterizar simultáneamente la capacidad explicativa, el error absoluto y la precisión relativa de cada algoritmo. Los resultados muestran que CatBoost alcanza el mejor



desempeño global, con el mayor valor medio de  $R^2$  (0.86) y el menor RMSE (1.04), acompañado de un MARD reducido (0.13) y un  $D_{10\%}$  de 11.38%. Este comportamiento evidencia una elevada capacidad del modelo para capturar relaciones no lineales, manteniendo a la vez un nivel bajo de variabilidad entre folds. De manera similar, Random Forest y GBRT exhiben un rendimiento competitivo, ambos con  $R^2 = 0.84$  y valores de RMSE cerca de 1.10, lo que indica una adecuada combinación entre estabilidad y precisión. LightGBM presenta un desempeño comparable ( $R^2 = 0.85$ ), aunque con ligeros incrementos en RMSE y  $D_{10\%}$  respecto a CatBoost.

Por el contrario, AdaBoost es el modelo con el rendimiento más limitado dentro del conjunto, obteniendo el menor  $R^2$  (0.75), el mayor RMSE (1.37) y el valor más alto de MARD (0.21). Este comportamiento sugiere que su estructura aditiva secuencial resulta menos adecuada para la complejidad del dataset 1, generando una menor estabilidad inter-folds.


En términos de precisión relativa, medida mediante  $D_{10\%}$ , destaca XGBoost, alcanzando el valor más bajo (9.02%), lo cual indica que una mayor proporción de sus predicciones presenta errores inferiores al 10%. Esto lo convierte en uno de los modelos más consistentes desde la perspectiva de control de error relativo, aun cuando su  $R^2$  sea ligeramente inferior al de CatBoost o LightGBM.

**Tabla 5 — Métricas de desempeño de los modelos de Ensemble Learning durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 1**

Modelo	R2	RMSE	MARD	D10
RF	0.84 (0.07)	1.11 (0.19)	0.13 (0.02)	9.49 (3.35)
AdaBoost	0.75 (0.08)	1.37 (0.17)	0.21 (0.04)	15.31 (4.54)
XGBoost	0.81 (0.07)	1.21 (0.16)	0.14 (0.02)	9.02 (3.97)
GBRT	0.84 (0.05)	1.09 (0.12)	0.14 (0.03)	11.25 (4.65)
CatBoost	0.86 (0.05)	1.04 (0.13)	0.13 (0.02)	11.38 (3.98)
LightGBM	0.85 (0.06)	1.07 (0.14)	0.14 (0.02)	11.62 (3.65)



La Figura 5 muestra que el modelo CatBoost fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.86$  y  $RMSE = 1.05$ .



**Figura 5 — Resultados de modelos de Ensemble Learning para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 1**

La Tabla 6 presenta los resultados obtenidos por los modelos de Ensemble Learning para el dataset 2, considerando los valores medios y sus desviaciones estándar derivados de 10 folds de validación cruzada.

El modelo XGBoost destaca como la alternativa con mejor equilibrio global: obtiene el mayor valor medio de  $R^2$  (0.87) y el menor RMSE (0.99), acompañado de un MARD reducido (0.12) y el valor más bajo de  $D_{10\%}$  (6.13%), lo que indica una alta consistencia en predicciones con errores relativos pequeños. Su estabilidad entre pliegues se refleja también en desviaciones estándar moderadas en todas las métricas.

Los modelos Random Forest y CatBoost muestran rendimientos muy cercanos, con  $R^2$  de 0.86 y RMSE en torno a 1.00 – 1.01, además de valores de MARD y  $D_{10\%}$  bajos (0.13 y 7.5, respectivamente). Esto evidencia que ambos métodos capturan adecuadamente las relaciones del dataset 2.

LightGBM mantiene un rendimiento competitivo, con resultados ligeramente inferiores a XGBoost y CatBoost, pero aún dentro del rango



de modelos de alta precisión. Su  $D_{10\%}$  (8.74) refleja una mayor dispersión en errores relativos. Por el contrario, GBRT exhibe un RMSE mayor (1.04) y un  $D_{10\%}$  de 11.39%, lo que sugiere una menor capacidad de generalización frente a los conjuntos de validación. Sin embargo, mantiene niveles aceptables de  $R^2$  (0.85), por lo que se desempeña de manera adecuada, aunque no óptima.


Finalmente, AdaBoost vuelve a mostrar limitaciones más marcadas: su  $R^2$  (0.77) es el menor del conjunto, y su RMSE (1.31) el más alto, acompañado de un  $D_{10\%}$  considerablemente elevado (20.03). Los resultados del dataset 2 refuerzan el buen desempeño de los modelos basados en boosting (especialmente XGBoost y CatBoost).

**Tabla 6 — Métricas de desempeño de los modelos de Ensemble Learning durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 2**

Modelo	R2	RMSE	MARD	D10
RF	0.86 (0.09)	1.01 (0.18)	0.13 (0.02)	7.55 (2.46)
AdaBoost	0.77 (0.10)	1.31 (0.16)	0.20 (0.02)	20.03 (7.73)
XGBoost	0.87 (0.06)	0.99 (0.14)	0.12 (0.02)	6.13 (3.43)
GBRT	0.85 (0.08)	1.04 (0.15)	0.14 (0.01)	11.39 (2.59)
CatBoost	0.86 (0.09)	1.00 (0.16)	0.13 (0.01)	7.42 (2.47)
LightGBM	0.85 (0.08)	1.03 (0.16)	0.13 (0.02)	8.74 (3.70)

La Figura 6 muestra que el modelo CatBoost fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.90$  y  $RMSE = 0.96$ .





**Figura 6 — Resultados de modelos de Ensemble Learning para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 2**

La Tabla 7 resume el desempeño de los modelos de Ensemble Learning para el dataset 3, utilizando los valores medios y desviaciones estándar derivados de la validación cruzada de 10 folds. Los modelos CatBoost y LightGBM alcanzan los valores más altos de  $R^2$  (0.87), acompañados de RMSE cercanos a 1.03. Ambos modelos mantienen valores estables de MARD (0.13–0.14), lo cual indica que su error relativo permanece controlado incluso bajo variaciones entre folds. De forma similar, XGBoost demuestra un rendimiento altamente competitivo, con  $R^2 = 0.85$  y  $RMSE = 1.10$ . Sin embargo, se distingue de los demás modelos por obtener el valor más bajo de  $D_{10\%}$  (6.79%), lo que evidencia una mayor proporción de predicciones con errores relativos inferiores al 10%.

El modelo Random Forest también muestra métricas equilibradas, con valores de  $R^2$  y RMSE comparables a los de XGBoost, aunque presenta una mayor dispersión en  $D_{10\%}$  (10.77), lo que indica mayor variabilidad en la precisión relativa entre pliegues.

En contraste con el resto de los modelos, AdaBoost vuelve a posicionarse como el modelo menos favorable. Su  $R^2$  (0.79) es el menor del conjunto, y su RMSE (1.34) el más elevado, acompañado además de un  $D_{10\%}$  de 18.73% en el dataset3, lo que refleja que el modelo AdaBoost no cuenta con una alta precisión predictiva por tener el menor valor de  $R^2$  (0.79) y


además presenta una predicción con rendimiento deficiente por tener valores elevados de los errores RMSE (1.34) y  $D_{10\%}$  de 18.73.

El análisis del dataset 3 confirma la tendencia observada en los datasets anteriores: los modelos basados en boosting de mayor complejidad (CatBoost, LightGBM y XGBoost) son los que mejor capturan la estructura del problema, mientras que AdaBoost presenta limitaciones sistemáticas frente a la naturaleza del conjunto de datos evaluado.

**Tabla 7 — Métricas de desempeño de los modelos de Ensemble Learning durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 3**

Modelo	R2	RMSE	MARD	D10
RF	0.85 (0.05)	1.10 (0.19)	0.13 (0.03)	10.77 (6.60)
AdaBoost	0.79 (0.03)	1.34 (0.13)	0.20 (0.03)	18.73 (6.46)
XGBoost	0.85 (0.05)	1.10 (0.17)	0.13 (0.02)	6.79 (2.74)
GBRT	0.86 (0.03)	1.08 (0.12)	0.14 (0.02)	12.93 (4.70)
CatBoost	0.87 (0.03)	1.02 (0.14)	0.13 (0.02)	10.94 (3.70)
LightGBM	0.87 (0.04)	1.03 (0.15)	0.14 (0.02)	13.39 (5.84)

La Figura 7 muestra que el modelo CatBoost fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.90$  y  $RMSE = 0.96$ .



**Figura 7 — Resultados de modelos de Ensemble Learning para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 3**



### 5.1.2.2 Resultados para el modelo SVM

La Tabla 8 presenta los valores medios y las desviaciones estándar obtenidas a partir de la validación cruzada de 10 folds para los seis modelos basados en Máquinas de Vectores de Soporte (SVM) evaluados con el dataset 1. Las métricas consideradas ( $R^2$ , RMSE, MARD y  $D_{10\%}$ ) permiten caracterizar tanto la capacidad explicativa como el error absoluto y relativo de cada configuración. Los resultados evidencian que todos los modelos SVM alcanzan un rendimiento homogéneo, con valores de  $R^2$  en el intervalo de 0.77 a 0.81 y RMSE entre 1.20 y 1.32, lo cual indica una variación moderada en el desempeño entre diferentes kernels. Entre ellos, el Fine Gaussian SVM obtuvo el mayor valor medio de  $R^2$  (0.81) y uno de los menores RMSE (1.20), acompañado además de desviaciones estándar relativamente bajas. Este comportamiento sugiere una mayor estabilidad inter-folds y una capacidad superior para capturar la relación no lineal entre las variables de entrada y la respuesta.

Por otro lado, el Cubic SVM presentó el menor valor medio de  $D_{10\%}$  (9.85%), evidenciando que una proporción más alta de sus predicciones presenta errores relativos inferiores al 10%. Esta métrica complementa la evaluación clásica basada en  $R^2$  y RMSE, indicando que el modelo es particularmente eficiente en términos de precisión relativa.

El Linear SVM, en contraste, mostró el rendimiento más limitado, con el menor  $R^2$  (0.77), el mayor RMSE (1.32) y el valor más elevado de  $D_{10\%}$  (20.64%), reflejando una capacidad reducida para capturar las no linealidades presentes en el dataset 1.


Los resultados muestran que las configuraciones con núcleos gaussianos (Fine y Medium Gaussian SVM) y el kernel cúbico exhiben el mejor equilibrio entre precisión y estabilidad, mientras que el modelo lineal constituye la alternativa menos adecuada para este problema. Estas observaciones respaldan la selección de un kernel no lineal como estrategia óptima para modelar el comportamiento del dataset 1.



**Tabla 8 — Métricas de desempeño de modelos SVM durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 1**

Modelo	R2	RMSE	MARD	D10%
Linear SVM	0.77 (0.08)	1.32 (0.18)	0.19 (0.05)	20.64 (4.78)
Quadratic SVM	0.79 (0.08)	1.26 (0.18)	0.17 (0.04)	12.46 (4.06)
Cubic SVM	0.78 (0.08)	1.28 (0.16)	0.16 (0.04)	9.85 (4.19)
Fine Gaussian SVM	0.81 (0.08)	1.20 (0.18)	0.16 (0.04)	12.01 (1.72)
Medium Gaussian SVM	0.80 (0.09)	1.21 (0.18)	0.15 (0.04)	10.73 (3.61)
Coarse Gaussian SVM	0.80 (0.08)	1.21 (0.19)	0.16 (0.04)	12.32 (4.26)

La Figura 8 muestra que el modelo Fine Gaussian SVM fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.81$  y  $RMSE = 1.17$ .



**Figura 8 — Resultados de modelos SVM para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 1**

La Tabla 9 resume los valores medios y las desviaciones estándar obtenidas mediante validación cruzada de 10 folds para los modelos SVM evaluados con el dataset 2. En este caso, los resultados muestran nuevamente un comportamiento relativamente uniforme entre los distintos kernels, aunque con variaciones más marcadas en términos de error absoluto (RMSE) y estabilidad inter-folds.

Los valores de  $R^2$  se encuentran en un rango estrecho (0.78–0.82), lo que indica que todas las configuraciones mantienen una capacidad explicativa similar. Sin embargo, los modelos basados en kernels gaussianos (Fine,



Medium y Coarse Gaussian SVM) alcanzan los valores medios de  $R^2$  más altos (0.82), evidenciando una ligera ventaja respecto de los kernels polinómicos y lineales.

En cuanto al RMSE, los mejores resultados corresponden al Medium Gaussian SVM y al Coarse Gaussian SVM (1.14), seguidos muy de cerca por el Fine Gaussian SVM (1.15). Esto sugiere que, para el dataset 2, los kernels gaussianos continúan proporcionando una aproximación más eficiente a la estructura del problema, aunque las diferencias respecto del kernel cuadrático son moderadas.

Las métricas de error relativo (MARD y  $D_{10\%}$ ) exhiben una tendencia coherente con las anteriores: todos los modelos gaussianos presentan los menores valores medios de  $D_{10\%}$  (13.62–15.99), indicando una mayor proporción de predicciones con errores inferiores al 10%.

El Linear SVM nuevamente muestra el rendimiento más limitado, con el mayor error relativo ( $D_{10\%} = 20.66$ ) y uno de los valores más altos de RMSE (1.23), lo cual confirma que un modelo lineal no logra capturar adecuadamente las relaciones no lineales del dataset 2.


**Tabla 9 — Métricas de desempeño de modelos SVM durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 2**

Modelo	R2	RMSE	MARD	$D_{10\%}$
Linear SVM	0.79 (0.09)	1.23 (0.11)	0.18 (0.02)	20.66 (6.04)
Quadratic SVM	0.81 (0.11)	1.18 (0.18)	0.16 (0.02)	16.12 (5.13)
Cubic SVM	0.78 (0.11)	1.29 (0.33)	0.16 (0.02)	14.11 (7.80)
Fine Gaussian SVM	0.82 (0.10)	1.15 (0.18)	0.16 (0.02)	15.99 (5.29)
Medium Gaussian SVM	0.82 (0.10)	1.14 (0.17)	0.16 (0.02)	13.62 (6.00)
Coarse Gaussian SVM	0.82 (0.10)	1.14 (0.17)	0.16 (0.02)	13.62 (6.00)

Los resultados del dataset 2 reafirman el patrón observado en el dataset 1: los kernels gaussianos especialmente las configuraciones Medium y Coarse logran un mejor equilibrio entre precisión, robustez y estabilidad.



La Figura 9 muestra que el modelo Medium Gaussian SVM fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.86$  y  $RMSE = 1.13$ .



**Figura 9 — Resultados de modelos SVM para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 2**

La Tabla 10 presenta las métricas promedio y las desviaciones estándar obtenidas mediante validación cruzada de 10 folds para los modelos SVM aplicados al dataset 3. Los resultados muestran un patrón consistente con los dos datasets anteriores, aunque con una menor dispersión en las métricas de precisión y estabilidad, lo cual sugiere que este conjunto de datos presenta una estructura interna más uniforme o menos ruidosa.

En términos de capacidad explicativa, los valores de  $R^2$  se ubican entre 0.79 y 0.84, siendo nuevamente los kernels gaussianos los que alcanzan el mejor desempeño. En particular, el Medium Gaussian SVM y el Coarse Gaussian SVM registran los valores medios más altos (0.84), seguidos de cerca por el Fine Gaussian SVM (0.83).

Los modelos gaussianos alcanzan los menores valores promedio de RMSE (1.15–1.17), indicando una mayor capacidad para reducir el error de predicción en comparación con los kernels polinómicos y lineales. En contraste, el Linear SVM mantiene nuevamente el desempeño más



limitado, con un RMSE de 1.33, lo cual confirma su incapacidad para modelar adecuadamente las no linealidades presentes en los datos.

Las métricas de error relativo (MARD y  $D_{10\%}$ ) también favorecen a los modelos gaussianos. El Medium Gaussian SVM alcanza el menor valor medio de  $D_{10\%}$  (13.84%), evidenciando una mayor proporción de predicciones con errores relativos inferiores al 10%. Los kernels cuadrático y cúbico presentan métricas idénticas ( $R^2 = 0.82$ ,  $RMSE = 1.20$ ,  $MARD = 0.17$ ,  $D_{10\%} = 14.61$ ), lo que indica que, para este dataset, ambos modelos tienen un nivel de desempeño equivalente.


Los resultados del dataset 3 refuerzan la tendencia observada en los datasets anteriores: las configuraciones gaussianas, y particularmente el Medium Gaussian SVM, ofrecen una combinación superior de precisión, estabilidad y robustez frente a la variabilidad inter-folds. Esto consolida la conclusión de que los kernels no lineales en especial los basados en funciones gaussianas constituyen la estrategia más adecuada para modelar el comportamiento predictivo en los tres conjuntos de datos analizados.

**Tabla 10 — Métricas de desempeño para modelos SVM durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 3**

Modelo	R2	RMSE	MARD	$D_{10\%}$
Linear SVM	0.79 (0.03)	1.33 (0.12)	0.19 (0.03)	19.20 (7.28)
Quadratic SVM	0.82 (0.05)	1.20 (0.19)	0.17 (0.03)	14.61 (5.17)
Cubic SVM	0.82 (0.05)	1.20 (0.19)	0.17 (0.03)	14.61 (5.17)
Fine Gaussian SVM	0.83 (0.05)	1.17 (0.17)	0.16 (0.02)	15.68 (7.31)
Medium Gaussian SVM	0.84 (0.04)	1.15 (0.17)	0.16 (0.02)	13.84 (7.50)
Coarse Gaussian SVM	0.84 (0.04)	1.16 (0.17)	0.16 (0.02)	15.08 (8.07)

La Figura 10 muestra que el modelo Medium Gaussian SVM fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.84$  y  $RMSE = 1.11$ .





**Figura 10 — Resultados de modelos SVM para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 3**

### 5.1.2.3 Resultados para el modelo ANN

La Tabla 11 presenta el desempeño de las arquitecturas de Artificial Neural Networks (ANN) evaluadas para el dataset 1, utilizando los valores medios y desviaciones estándar obtenidos mediante validación cruzada de 10 folds. En general, se observa que todas las configuraciones logran capturar parcialmente la estructura del conjunto de datos, aunque con niveles de precisión menores respecto a los modelos de Ensemble Learning.

Las redes Narrow NN y Wide NN son las que alcanzan el mejor equilibrio dentro del grupo, ambas con valores de  $R^2$  cercanos a 0.72 y RMSE alrededor de 1.45–1.46. Estos resultados indican que incrementar moderadamente el número de neuronas por capa contribuye a mejorar la capacidad de ajuste sin comprometer la estabilidad entre folds, como lo reflejan sus desviaciones estándar relativamente bajas.

La arquitectura Medium NN muestra un rendimiento muy similar, aunque con un ligero incremento en RMSE (1.47) y en MARD (0.21), lo que sugiere que los cambios en tamaño de capa no generan mejoras sustanciales en la captura de no linealidades para este dataset.

Por otro lado, aumentar la profundidad de la red no conduce a un mejor desempeño. La Two Layer NN reduce su  $R^2$  a 0.68 y aumenta su RMSE a 1.55, indicando que la mayor complejidad de la arquitectura no se traduce

en una mayor capacidad predictiva; por el contrario, parece introducir variabilidad adicional sin mejorar la representación del fenómeno. Este patrón se acentúa en la Three Layer NN, que registra el menor  $R^2$  (0.65), el mayor RMSE (1.61) y el valor más alto de MARD (0.22), lo cual evidencia dificultades de entrenamiento asociadas a sobreparametrización relativa al tamaño del dataset.


Las arquitecturas (Narrow, Medium y Wide NN) ofrecen el mejor rendimiento dentro del conjunto, mientras que las redes más profundas (Two Layer y Three Layer NN) muestran limitaciones más marcadas. Estos resultados evidencian que, para el dataset 1, incrementar la complejidad de la red no se traduce en mejoras predictivas y puede, incluso, deteriorar su capacidad de generalización.

**Tabla 11 — Métricas de desempeño de los modelos ANN durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 1**

Modelo	R2	RMSE	MARD	D <sub>10%</sub>
Narrow NN	0.72 (0.10)	1.45 (0.23)	0.20 (0.05)	18.92 (8.34)
Medium NN	0.71 (0.11)	1.47 (0.24)	0.21 (0.06)	19.61 (6.87)
Wide NN	0.72 (0.10)	1.46 (0.21)	0.21 (0.05)	18.74 (7.02)
Two Layer NN	0.68 (0.10)	1.55 (0.20)	0.21 (0.04)	17.55 (7.16)
Three Layer NN	0.65 (0.13)	1.61 (0.28)	0.22 (0.05)	22.17 (8.04)

La Figura 11 muestra que el modelo Wide NN fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.84$  y  $RMSE = 1.11$ .





**Figura 11 — Resultados de modelos ANN para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 1**

La Tabla 12 presenta el desempeño de los modelos de ANN evaluadas para el dataset 2, utilizando los valores medios y desviaciones estándar obtenidos mediante validación cruzada de 10 folds. Para el dataset 2, las arquitecturas de una sola capa muestran el mejor desempeño. El Medium ANN alcanza el mayor valor medio de  $R^2$  (0.82), mientras que el Wide ANN presenta los valores mínimos de RMSE (1.15) y MARD (0.14), además del menor  $D_{10}$  (9.25%). Estos resultados indican que el incremento en el número de neuronas mejora la capacidad de representación sin comprometer la estabilidad en la validación cruzada.


Las arquitecturas más profundas (Two Layer ANN y Three Layer ANN) no generan mejoras significativas. Ambas muestran una reducción consistente en  $R^2$  y un aumento en RMSE respecto a los modelos de una sola capa, lo que sugiere que la mayor profundidad no es beneficiosa para la estructura del dataset 2 y puede inducir a sobreajuste ligero. La variabilidad observada en la desviación estándar del RMSE refuerza esta conclusión.



**Tabla 12 — Métricas de desempeño de los modelos ANN durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 2**

Modelo	R2	RMSE	MARD	D <sub>10%</sub>
Narrow NN	0.80 (0.09)	1.20 (0.14)	0.16 (0.02)	14.30 (6.03)
Medium NN	0.82 (0.10)	1.14 (0.19)	0.15 (0.02)	14.53 (7.59)
Wide NN	0.82 (0.09)	1.15 (0.13)	0.14 (0.02)	9.25 (2.62)
Two Layer NN	0.80 (0.10)	1.22 (0.24)	0.15 (0.03)	12.00 (2.89)
Three Layer NN	0.75 (0.11)	1.37 (0.29)	0.16 (0.02)	11.88 (4.28)

La Figura 12 muestra que el modelo Wide NN fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.85$  y  $RMSE = 1.17$ .



**Figura 12 — Resultados de modelos ANN para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 2**

La Tabla 13 presenta el desempeño de los modelos de ANN evaluadas para el dataset 3, utilizando los valores medios y desviaciones estándar obtenidos mediante validación cruzada de 10 folds. Para el dataset 3, las arquitecturas de una sola capa muestran un buen desempeño, destacando el Wide ANN, que alcanza el mayor  $R^2$  (0.84) y los valores mínimos de RMSE (1.13) y MARD (0.15), lo que indica una mayor capacidad de generalización respecto a las configuraciones más estrechas. El Medium ANN también presenta un rendimiento adecuado, aunque con errores ligeramente superiores y una dispersión mayor en el  $D_{10\%}$ .




En cuanto a las arquitecturas profundas, el Two Layer ANN mantiene un desempeño comparable al Wide ANN en términos de MARD (0.15), pero con un RMSE superior (1.23) y mayor variabilidad en la validación cruzada. Por su parte, el Three Layer ANN presenta el menor  $R^2$  (0.79) y los mayores valores de RMSE, lo que evidencia un deterioro en el ajuste asociado al incremento en profundidad.

**Tabla 13 — Métricas de desempeño de los modelos ANN durante el entrenamiento y valores medios (desviación estándar) de la validación cruzada para el dataset 3**

Modelo	R2	RMSE	MARD	D <sub>10%</sub>
Narrow NN	0.80 (0.06)	1.29 (0.20)	0.18 (0.03)	17.10 (3.97)
Medium NN	0.83 (0.06)	1.19 (0.21)	0.16 (0.02)	15.19 (6.53)
Wide NN	0.84 (0.05)	1.13 (0.21)	0.15 (0.02)	10.11 (3.88)
Two Layer NN	0.81 (0.08)	1.23 (0.27)	0.15 (0.02)	8.90 (2.56)
Three Layer NN	0.79 (0.08)	1.31 (0.26)	0.16 (0.02)	10.83 (3.63)

La Figura 13 muestra que el modelo Wide NN fue el más preciso (la mejor mediana de rendimientos) y exacto (cajas más cortas y menos valores atípicos), con valores medianos de  $R^2 = 0.84$  y  $RMSE = 1.11$ .



**Figura 13 — Resultados de modelos ANN para la validación cruzada en términos de (a)  $R^2$  y (b) RMSE para el dataset 3**

### 5.1.3 Optimización y validación del modelo final

El método de búsqueda en cuadrícula fue adoptado para optimizar los hiperparámetros de todos los modelos, el cual evalúa iterativamente diferentes



combinaciones de hiperparámetros hasta encontrar la que produce la mayor precisión. La evaluación de las diferentes combinaciones de hiperparámetros requiere el uso de la validación cruzada CV de K-pliegues. La búsqueda en cuadrícula se realizó utilizando  $K = 5$  para la validación cruzada.

### 5.1.3.1 Resultados para los modelos de Ensemble Learning

Los hiperparámetros optimizados de los modelos de Ensemble Learning para el dataset 1, 2 y 3 se resumen en la Tabla 14.

**Tabla 14 — Optimización de hiperparámetros de modelos de Ensemble Learning**

Modelo	Parámetro	Grid evaluado	Dataset 1 valor	Dataset 2 valor	Dataset 3 valor
Random Forest (RF)	n_estimators (número de árboles)	[40, 60, 80, 100]	60	40	100
	max_depth (profundidad máxima)	[6, 8, 10, 12]	12	12	12
	max_features (n° de características)	[8, 10, 12, 14]	10	8	8
LightGBM (LGBM)	n_estimators (número de árboles)	[400, 500, 600, 700]	500	700	400
	Learning_rate (tasa de aprendizaje)	[0.01, 0.02, 0.1, 0.5]	0.02	0.02	0.1
	max_depth (profundidad máxima)	[7, 8, 9, 10]	10	10	9
Gradient Boosting (GBRT)	n_estimators (número de árboles)	[200, 400, 500, 600]	400	600	400
	Learning_rate (tasa de aprendizaje)	[0.01, 0.02, 0.1, 0.5]	0.02	0.01	0.1
	max_depth (profundidad máxima)	[7, 8, 9, 10]	7	7	7
AdaBoost	n_estimators (número de árboles)	[200, 300, 400, 600]	300	600	600
	Learning_rate (tasa de aprendizaje)	[0.01, 0.05, 0.1, 0.2]	0.1	0.2	0.2
	max_depth (profundidad máxima)	[3, 5, 7, 9]	7	9	9
XGBoost (XGB)	n_estimators (número de árboles)	[100, 200, 400, 600]	600	600	600
	Learning_rate (tasa de aprendizaje)	[0.01, 0.02, 0.1, 0.5]	0.01	0.02	0.02
	max_depth (profundidad máxima)	[7, 8, 9, 10]	7	7	7
CatBoost	n_estimators (número de árboles)	[600, 800, 900, 1000]	900	1000	800
	Learning_rate (tasa de aprendizaje)	[0.01, 0.02, 0.05, 0.1]	0.05	0.05	0.1
	max_depth (profundidad máxima)	[4, 6, 8, 10]	4	4	6

La Figura 14 muestra los resultados de la búsqueda en cuadrícula en términos de  $R^2$  para los hiperparámetros del modelo de CatBoost para el dataset 1. Se encontró que tres hiperparámetros impactaban significativamente la capacidad predictiva del modelo CatBoost: (1) número de estimadores: [600, 800, 900 y 1000]; (2) tasa de aprendizaje: [0.01, 0.02, 0.05 y 0.1]; y (3) profundidad máxima: [4, 6, 8 y 10]. Aunque el modelo tendrá un rendimiento similar con 600, 800, 900 o 1000 estimadores, se eligieron 900 estimadores ya que proporcionaron el valor más alto de  $R^2$ . Por lo tanto, la combinación óptima de hiperparámetros para el modelo CatBoost fue de 900 estimadores, una tasa de aprendizaje de 0.05 y una profundidad máxima de 4.



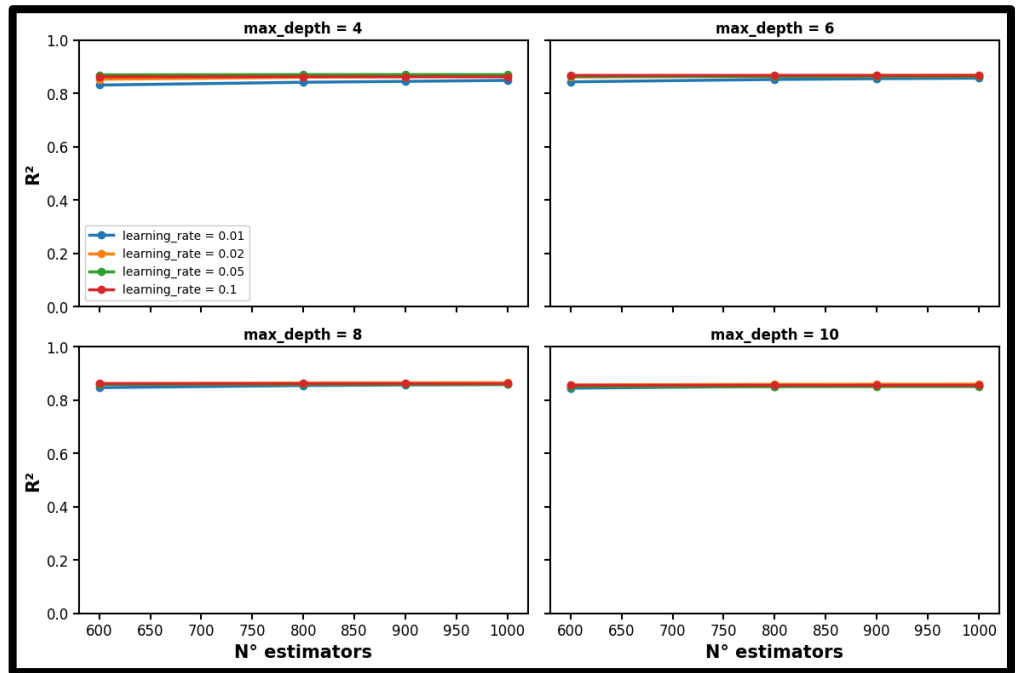


Figura 14 — Búsqueda en cuadrícula de los hiperparametros óptimos del modelo CatBoost para el dataset 1

La Figura 15 muestra los resultados de la búsqueda en cuadrícula en términos de  $R^2$  para los hiperparámetros del modelo de CatBoost para el dataset 2.

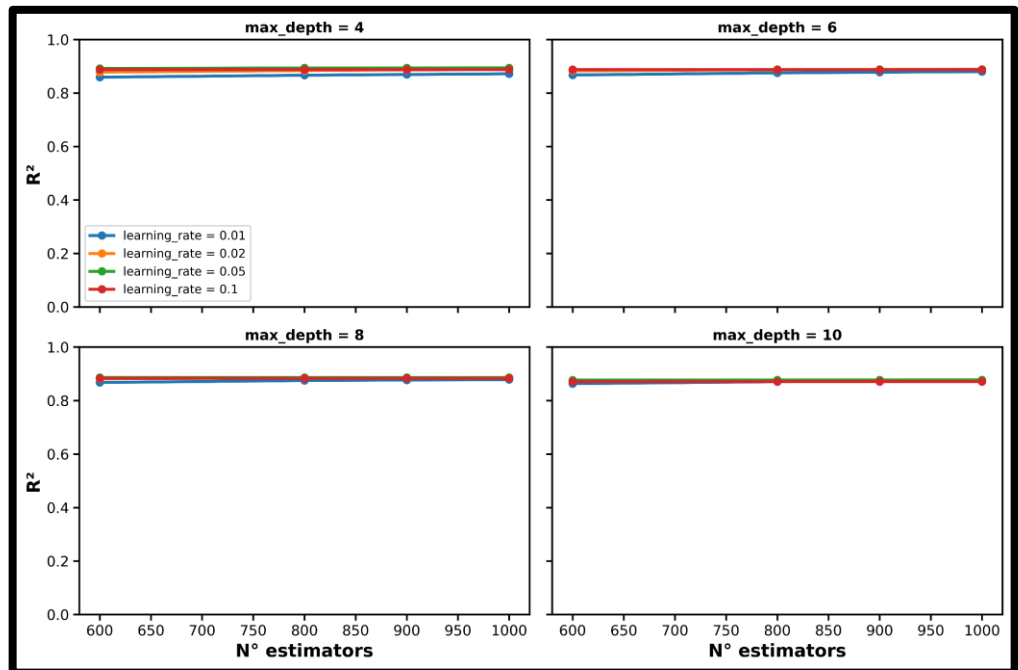



Figura 15 — Búsqueda en cuadrícula de los hiperparametros óptimos del modelo CatBoost para el dataset 2



La combinación óptima de hiperparámetros del modelo CatBoost para el dataset 2 fue de 1000 estimadores, una tasa de aprendizaje de 0.05 y una profundidad máxima de 4.

La Figura 16 muestra los resultados de la búsqueda en cuadrícula en términos de  $R^2$  para los hiperparámetros del modelo de CatBoost para el dataset 3. La combinación óptima de hiperparámetros del modelo CatBoost para el dataset 3 fue de 800 estimadores, una tasa de aprendizaje de 0.1 y una profundidad máxima de 6.

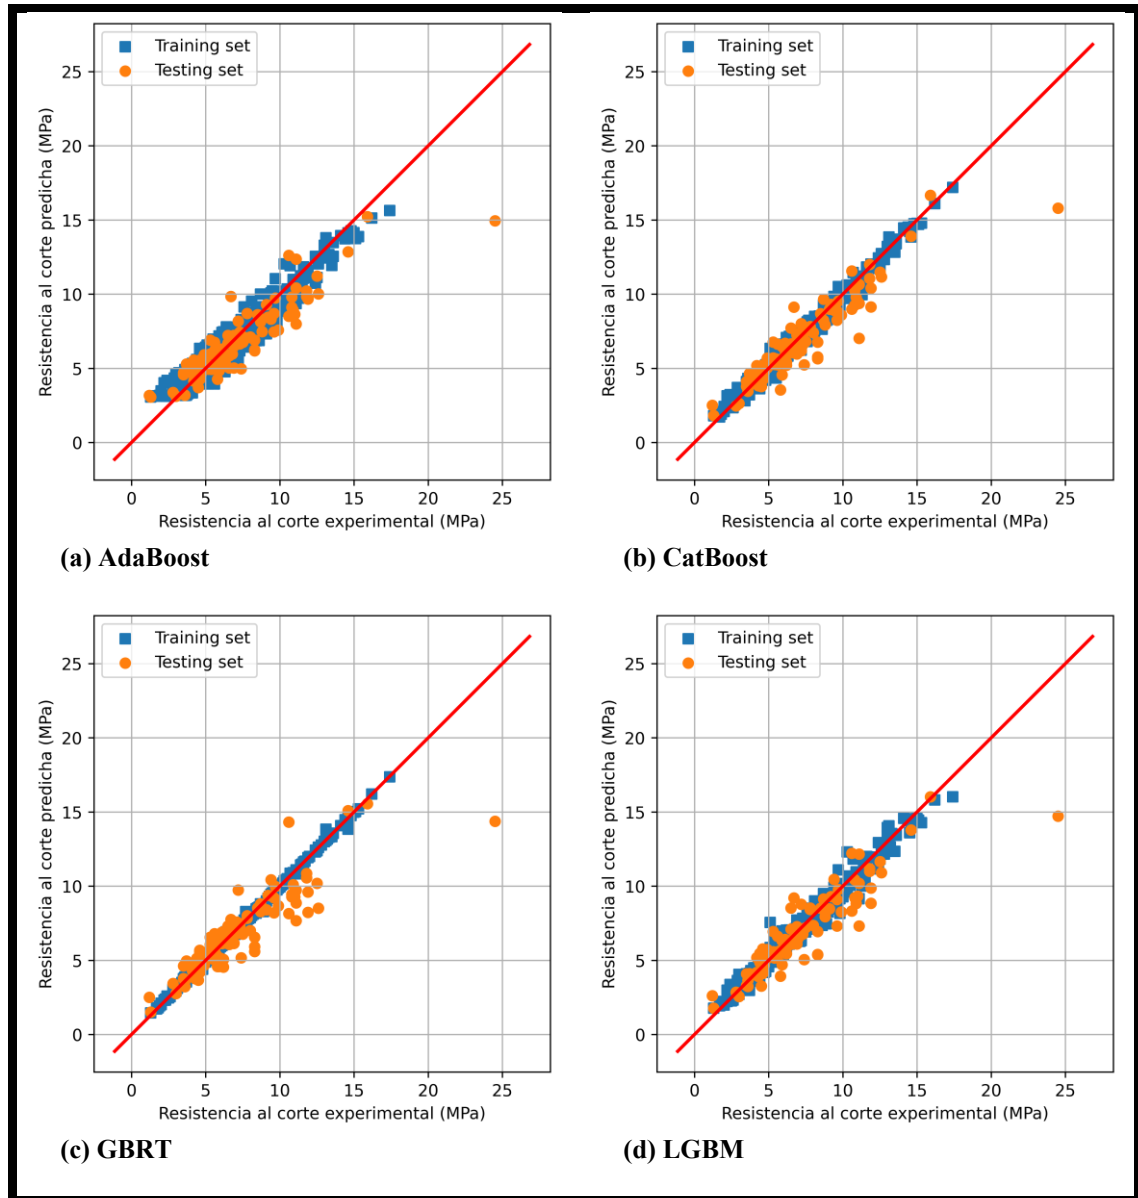


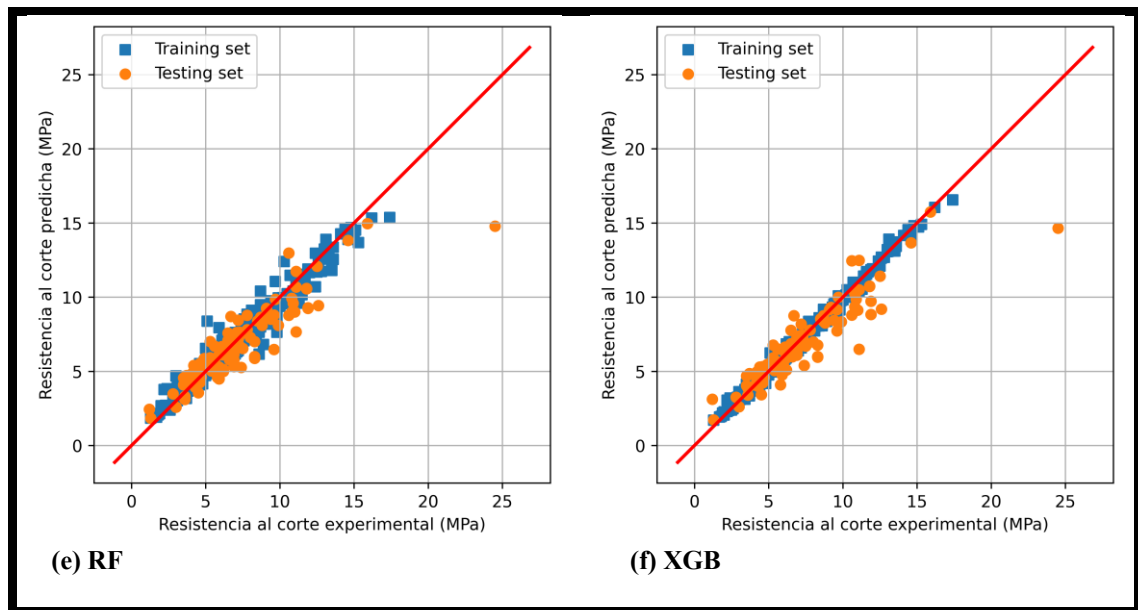
**Figura 16 — Búsqueda en cuadrícula de los hiperparámetros óptimos del modelo CatBoost para el dataset 3**

Con base de estos hiperparámetros óptimos de los seis modelos y el conjunto completo de datos de entrenamiento, se construyeron seis modelos para los tres datasets. Para el dataset 1 el modelo CatBoost mostró el mejor desempeño. El rendimiento de estos seis modelos se evalúa utilizando el conjunto de datos de prueba, comparando los resultados predichos con los datos experimentales, como se muestra en la Figura 17. La línea diagonal representa que la predicción es idéntica a los datos experimentales. Se puede observar que, en general, los seis modelos de



Ensemble Learning obtuvieron buenos resultados, ya que los diagramas de dispersión están muy cerca de la diagonal. Se observaron algunos valores atípicos en el conjunto de prueba (Figura 17).






**Figura 17 — Resultados de la resistencia al corte predichos por diferentes modelos de Ensemble Learning para el dataset 1**

La Figura 18 y la Tabla 15 comparan las métricas de desempeño de los modelos de Ensemble Learning para el dataset 1. El modelo CatBoost mostró el mejor desempeño con valores de  $R^2 = 0.84$  y  $RMSE = 1.269$  para el set de testing. Además, las otras métricas indicaron la superioridad del modelo CatBoost. Hubo solo una reducción menor en el rendimiento del modelo desde el conjunto de entrenamiento al conjunto de prueba de un valor de  $R^2$  de 0.986 a 0.84.

**Tabla 15 — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 1**

Modelos	Sets	Métricas					
		$R^2$	RMSE	MAE	MAPE (%)	MARD	$D_{10\%}$
AdaBoost	Training	0.915	0.842	0.699	13.61	0.136	12.22
	Testing	0.786	1.467	0.976	15.18	0.152	11.99
CatBoost	Training	0.986	0.339	0.26	4.70	0.047	4.48
	Testing	0.84	1.269	0.746	10.68	0.107	9.5
GBRT	Training	0.998	0.123	0.078	1.48	0.015	0.71
	Testing	0.772	1.514	0.901	12.30	0.123	9.86
LGBM	Training	0.977	0.443	0.31	5.31	0.053	3.92
	Testing	0.803	1.41	0.826	11.68	0.117	7.02
RF	Training	0.961	0.57	0.39	6.84	0.068	4.45
	Testing	0.798	1.427	0.887	12.75	0.128	10.67
XGB	Training	0.992	0.251	0.183	3.49	0.035	2.74
	Testing	0.802	1.414	0.817	11.88	0.119	4.10





**Figura 18 — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 1**


La Figura 19, Figura 20 y la Tabla 16 comparan las métricas de desempeño de los modelos de Ensemble Learning para el dataset 2. El modelo CatBoost mostró el mejor desempeño con valores de  $R^2 = 0.835$  y  $RMSE = 1.118$  para el set de testing. Hubo solo una reducción menor en el rendimiento del modelo desde el conjunto de entrenamiento al conjunto de prueba de un valor de  $R^2$  de 0.991 a 0.835.

**Tabla 16 — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 2**

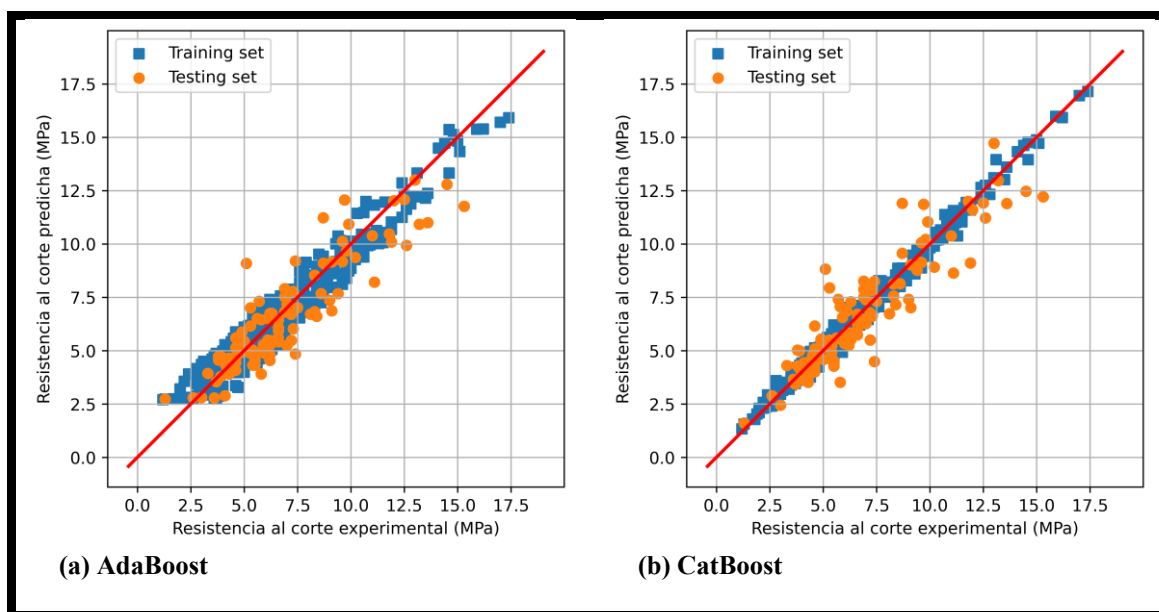
Modelos	Sets	Métricas					
		R <sup>2</sup>	RMSE	MAE	MAPE (%)	MARD	D <sub>10%</sub>
AdaBoost	Training	0.933	0.755	0.647	12.51	0.125	13.09
	Testing	0.807	1.21	0.924	14.48	0.145	12.9
CatBoost	Training	0.991	0.273	0.211	3.81	0.038	3.83
	Testing	0.835	1.118	0.815	12.33	0.123	13.87
GBRT	Training	0.998	0.118	0.075	1.44	0.014	0.9
	Testing	0.787	1.271	0.906	13.8	0.138	8.91
LGBM	Training	0.987	0.335	0.234	4.14	0.041	2.68
	Testing	0.82	1.166	0.852	12.65	0.127	10.29
RF	Training	0.965	0.543	0.372	6.53	0.065	3.63

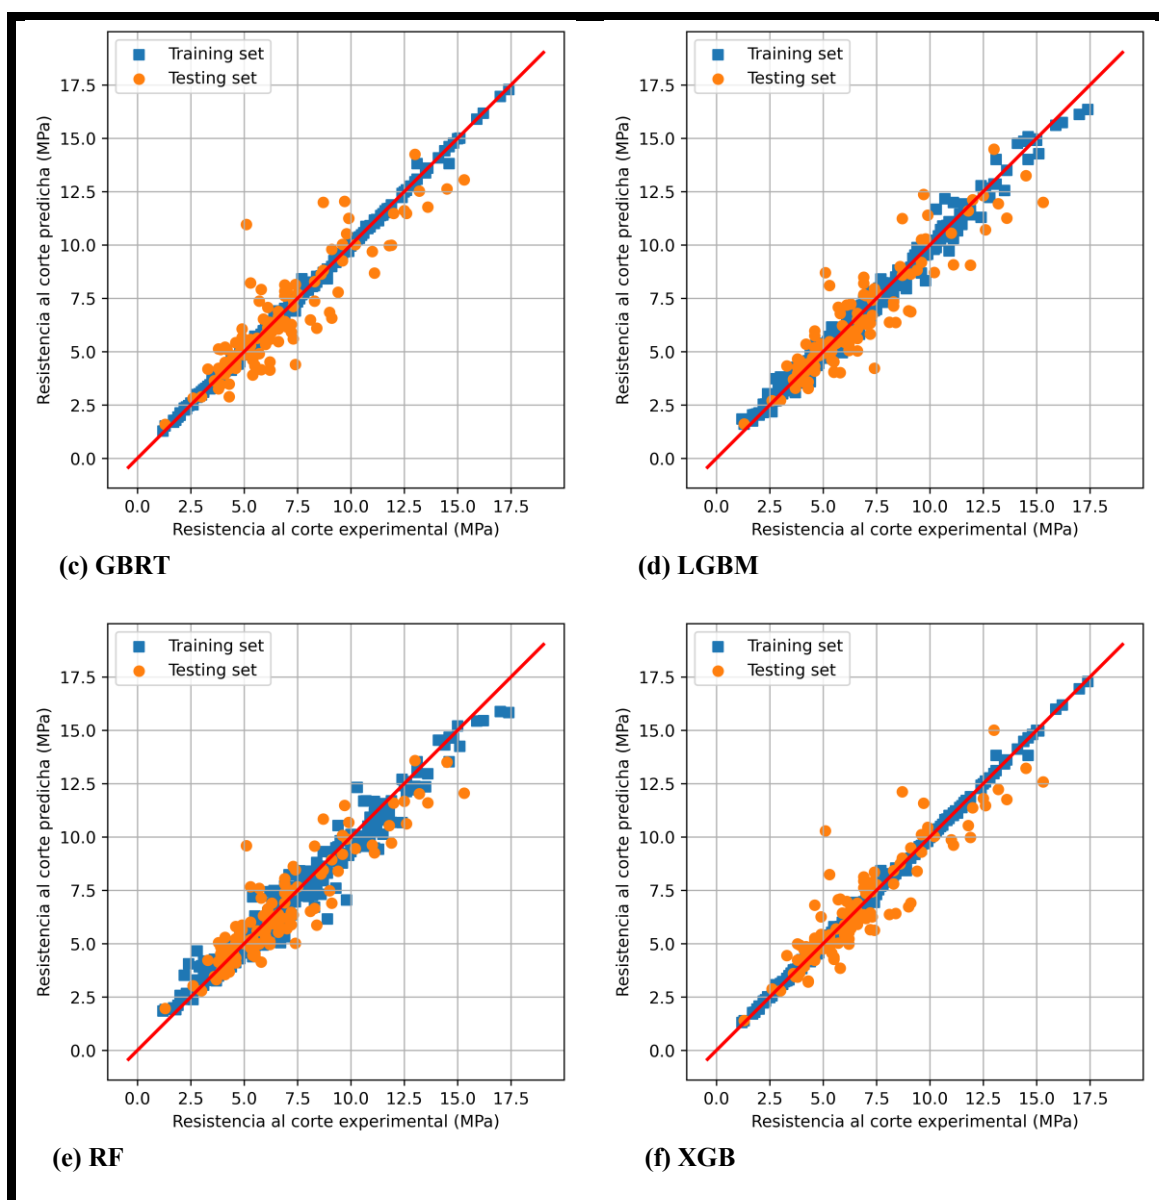


	Testing	0.833	1.124	0.846	13.1	0.131	12.45
<b>XGB</b>	Training	0.999	0.108	0.065	1.19	0.012	0.74
	Testing	0.824	1.155	0.831	12.7	0.127	11.47



**Figura 19 — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 2**





**Figura 20 — Resultados de la resistencia al corte predichos por diferentes modelos de Ensemble Learning para el dataset 2**

La Figura 21, Figura 22 y la Tabla 17 comparan las métricas de desempeño de los modelos de Ensemble Learning para el dataset 3. El modelo CatBoost mostró el mejor desempeño con valores de  $R^2 = 0.893$  y  $RMSE = 0.992$  para el set de testing. Hubo solo una reducción menor en el rendimiento del modelo desde el conjunto de entrenamiento al conjunto de prueba de un valor de  $R^2$  de 0.998 a 0.893.



Tabla 17 — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 3

Modelos	Sets	Métricas					
		R <sup>2</sup>	RMSE	MAE	MAPE (%)	MARD	D <sub>10%</sub>
AdaBoost	Training	0.919	0.839	0.722	14.05	0.141	15.6
	Testing	0.851	1.171	0.912	15.79	0.158	14.33
CatBoost	Training	0.998	0.122	0.083	1.44	0.014	1.41
	Testing	0.893	0.992	0.691	10.86	0.109	6.11
GBRT	Training	0.999	0.075	0.014	0.19	0.002	0.03
	Testing	0.86	1.136	0.75	11.28	0.113	5.66
LGBM	Training	0.996	0.185	0.123	2.16	0.022	1.39
	Testing	0.887	1.023	0.76	12.11	0.121	9.3
RF	Training	0.962	0.573	0.402	7.02	0.07	3.79
	Testing	0.896	0.978	0.693	11.33	0.113	8.25
XGB	Training	0.998	0.123	0.08	1.46	0.015	0.95
	Testing	0.878	1.061	0.729	11.21	0.112	7.99


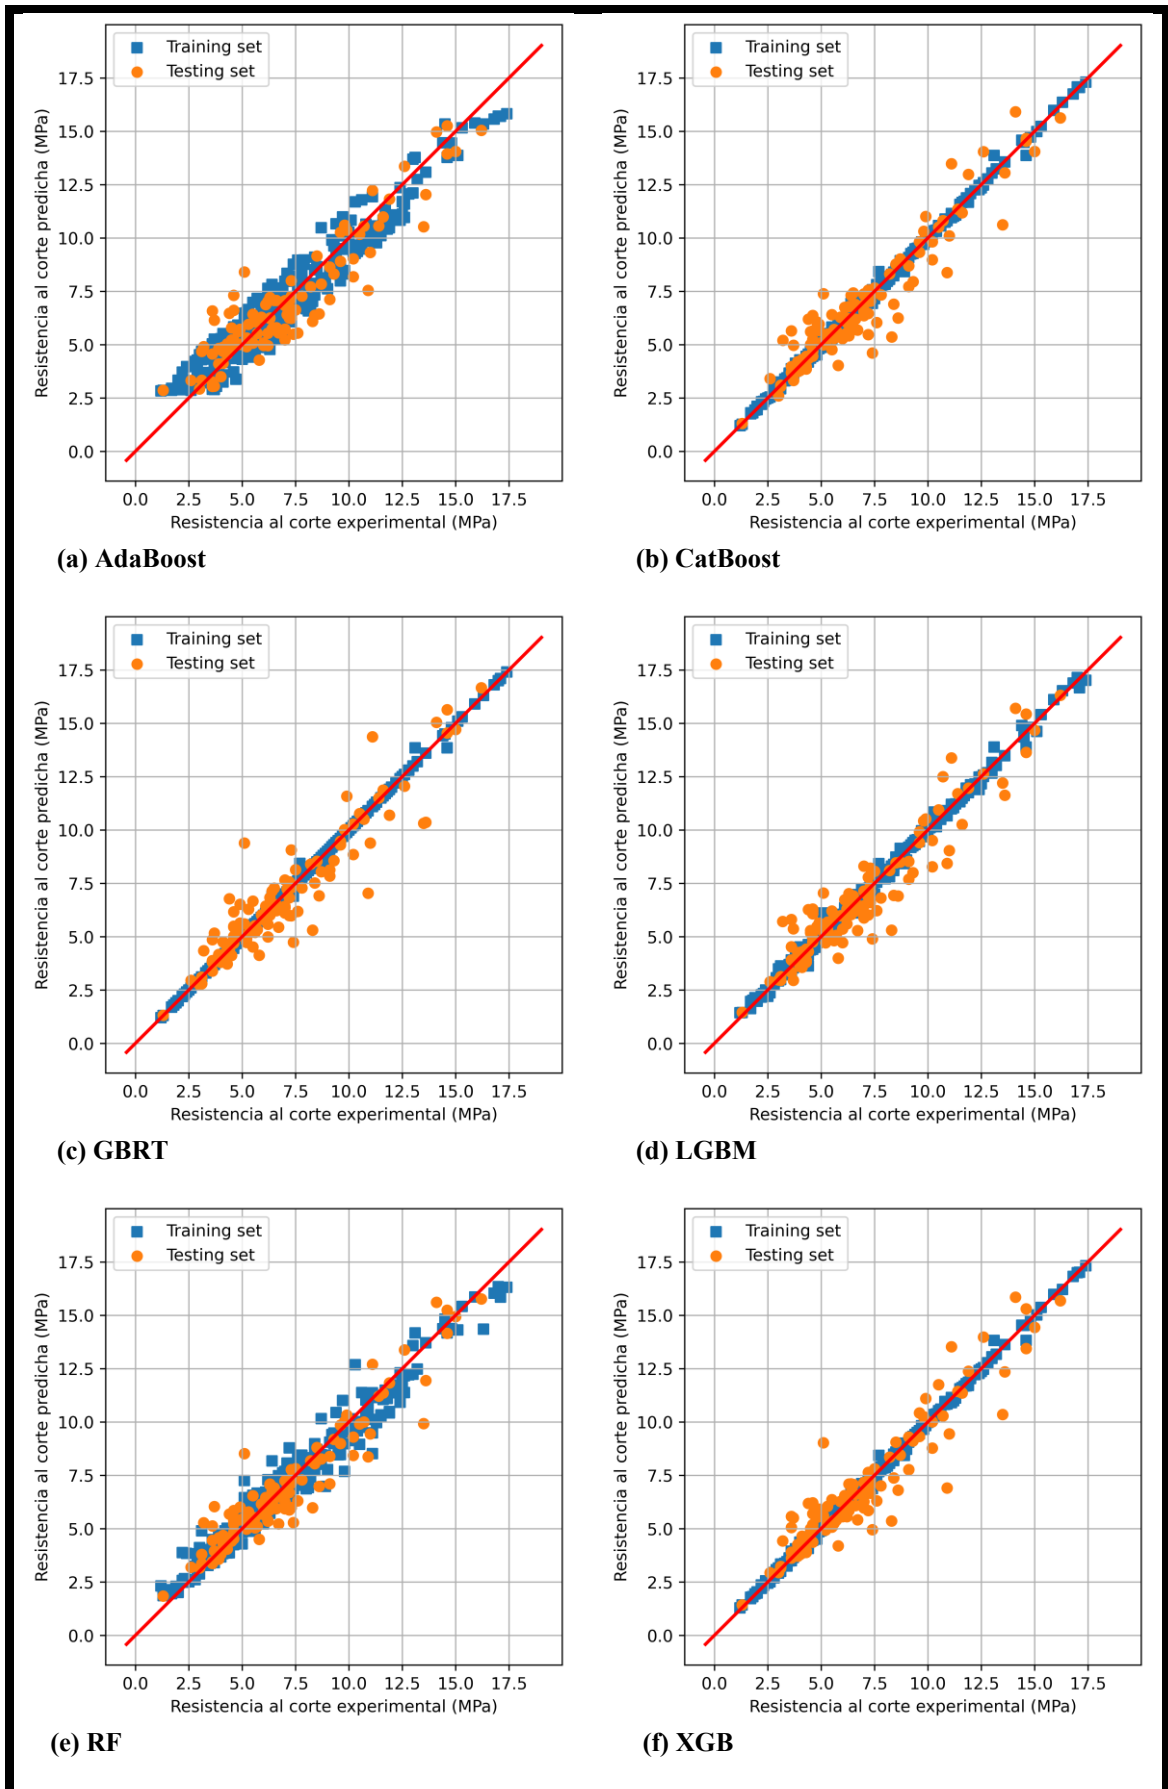


Figura 21 — Métricas de desempeño para los modelos de Ensemble Learning optimizados para el dataset 3



**Figura 22 — Resultados de la resistencia al corte predichos por diferentes modelos de Ensemble Learning para el dataset 3**



### 5.1.3.2 Resultados para el modelo SVM

Para el dataset 1, el modelo SVM Fine Gaussian presentó el mejor desempeño. La selección de hiperparámetros se realizó mediante Grid Search, considerando los parámetros  $C$ ,  $\gamma$  y  $\epsilon$ , y utilizando una validación cruzada de 10 particiones (10-fold cross-validation). Como métrica objetivo durante el proceso de optimización se utilizó el error cuadrático medio negativo. El espacio de búsqueda incluyó  $C = [1, 10, 50, 100]$ ,  $\gamma = [0.01, 0.05, 0.1]$  y  $\epsilon = [0.05, 0.1, 0.5]$ . Como resultado del proceso de optimización, la combinación de hiperparámetros que presentó el mejor desempeño fue  $C = 50$ ,  $\gamma = 0.05$  y  $\epsilon = 0.5$ , la cual fue utilizada para entrenar el modelo final.


La Figura 23 muestra la comparación entre la resistencia al corte experimental y la resistencia al corte predicha por el modelo SVM optimizado para el dataset 1. La línea diagonal representa la predicción perfecta. Se observa que los puntos del conjunto de entrenamiento se distribuyen cercanos a dicha línea, mientras que en el conjunto de prueba se presenta una mayor dispersión, lo que indica una disminución de la capacidad predictiva del modelo.

Las métricas de desempeño obtenidas se resumen en la Tabla 18. En el conjunto de entrenamiento se alcanzó un coeficiente de determinación  $R^2 = 0.944$ , mientras que en el conjunto de prueba este valor disminuyó a  $R^2 = 0.562$ , lo que evidencia una pérdida significativa de capacidad de generalización. Este comportamiento se refleja también en el aumento de los errores RMSE y MAE, que pasaron de 0.68 a 2.10 y de 0.52 a 1.05, respectivamente. En cuanto a los indicadores de error relativo, el valor de  $D_{10}\%$  fue 11.10% en el conjunto de entrenamiento y 14.05% en el conjunto de prueba, lo que indica que únicamente ese porcentaje de las predicciones presenta un error relativo menor o igual al 10%. Los valores de MAPE y MARD también aumentaron en el conjunto de prueba, confirmando la degradación del desempeño predictivo.



**Tabla 18 — Métricas de desempeño del modelo SVM optimizado para el dataset 1**

Data set	R <sup>2</sup>	RMSE	MAE	MAPE	MARD	D <sub>10%</sub>
Training	0.944	0.684	0.524	9.86	0.093	11.10
Testing	0.562	2.10	1.052	14.31	0.143	14.05



**Figura 23 — Resultado de la resistencia al corte predicho por el modelo SVM optimizado para el dataset 1**

Para el dataset 2 el modelo SVM Medium Gaussian mostró el mejor desempeño, se empleó un modelo de Support Vector Regression (SVR) con kernel Gaussiano (RBF). La selección de hiperparámetros se realizó mediante una búsqueda exhaustiva (Grid Search) considerando los parámetros  $C$ ,  $\gamma$  y  $\epsilon$ , con una validación cruzada de 10 particiones (10-fold cross-validation) y como función objetivo el error cuadrático medio negativo. El espacio de búsqueda incluyó  $C = [10, 50, 100, 200]$ ,  $\gamma = [0.005, 0.01, 0.02]$  y  $\epsilon = [0.05, 0.1, 0.2]$ . La combinación óptima obtenida fue  $C = 50$ ,  $\gamma = 0.005$  y  $\epsilon = 0.2$ , la cual fue utilizada para entrenar el modelo.

La Figura 24 presenta la comparación entre los valores experimentales y los valores predichos de la resistencia al corte para los conjuntos de entrenamiento y prueba. La proximidad de los puntos a la línea de identidad indica una relación aproximadamente lineal entre valores reales




y predichos. No se observa un sesgo sistemático evidente a lo largo del rango de valores analizado, aunque existe dispersión residual, particularmente en los valores más elevados.

Las métricas de desempeño obtenidas se resumen en la Tabla 19. En el conjunto de entrenamiento se obtuvo  $R^2 = 0.867$ , mientras que en el conjunto de prueba el valor fue  $R^2 = 0.806$ , lo que indica una reducción limitada del desempeño. Los errores RMSE y MAE aumentaron de 1.06 a 1.21 y de 0.78 a 0.92, respectivamente, comportamiento consistente con la evaluación del modelo fuera del conjunto de entrenamiento.

En cuanto a los indicadores de error relativo, el valor de  $D_{10\%}$  fue 13.75% para el conjunto de entrenamiento y 12.38% para el conjunto de prueba, lo que implica que solo ese porcentaje de las predicciones presenta un error relativo menor o igual al 10%.

**Tabla 19 — Métricas de desempeño del modelo SVM optimizado para el dataset 2**

Data set	$R^2$	RMSE	MAE	MAPE	MARD	$D_{10\%}$
Training	0.867	1.06	0.779	14.56	0.137	13.75
Testing	0.806	1.211	0.915	15.33	0.153	12.38



**Figura 24 — Resultado de la resistencia al corte predicho por el modelo SVM optimizado para el dataset 2**


Para el dataset 3 el modelo SVM Medium Gaussian mostró el mejor desempeño. La selección de hiperparámetros se realizó mediante una búsqueda exhaustiva (Grid Search), considerando los parámetros  $C$ ,  $\gamma$  y  $\varepsilon$ , y utilizando una validación cruzada de 10 particiones (10-fold cross-validation). Como métrica objetivo durante el proceso de optimización se utilizó el error cuadrático medio negativo. El espacio de búsqueda incluyó  $C = [10, 50, 100, 200]$ ,  $\gamma = [0.005, 0.01, 0.02]$  y  $\varepsilon = [0.05, 0.1, 0.2]$ . Los mejores parámetros encontrados para este modelo fueron  $C = 50$ ,  $\gamma = 0.02$  y  $\varepsilon = 0.2$ , los cuales fueron utilizados para entrenar el modelo final.

La Figura 25 presenta la comparación entre la resistencia al corte experimental y la resistencia al corte predicha por el modelo SVM optimizado para el dataset 3. Las métricas de desempeño se resumen en la Tabla 20. En el conjunto de entrenamiento se obtuvo un coeficiente de determinación  $R^2 = 0.896$ , mientras que en el conjunto de prueba se alcanzó  $R^2 = 0.846$ , lo que indica una reducción limitada del desempeño. Los valores de RMSE y MAE aumentaron de 0.95 a 1.19 y de 0.67 a 0.86, respectivamente, lo que es esperado al evaluar el modelo sobre el conjunto de prueba.

**Tabla 20 — Métricas de desempeño del modelo SVM optimizado para el dataset 3**

Data set	$R^2$	RMSE	MAE	MAPE	MARD	$D_{10\%}$
Training	0.896	0.951	0.672	12.49	0.118	12.87
Testing	0.846	1.193	0.857	14.37	0.144	12.53





**Figura 25 — Resultado de la resistencia al corte predicho por el modelo SVM optimizado para el dataset 3**

### 5.1.3.3 Resultados para el modelo ANN

La Tabla 21 resume las métricas de desempeño final obtenidas por los distintos modelos de redes neuronales artificiales (ANN) optimizados para el dataset 1, tanto en las fases de entrenamiento como de prueba, utilizando indicadores globales de ajuste ( $R^2$ ), error absoluto y relativo (RMSE, MAE, MAPE, MARD) y la métrica de robustez D10.

En la etapa de entrenamiento, los modelos ANN\_Two\_Layer y ANN\_Wide presentan los valores más elevados de coeficiente de determinación ( $R^2 = 0.970$  y  $0.966$ , respectivamente), acompañados de errores significativamente reducidos ( $RMSE \leq 0.53$  y  $MAE \leq 0.39$ ), lo que evidencia una alta capacidad de ajuste a los datos observados. El modelo ANN\_Three\_Layer también muestra un desempeño competitivo ( $R^2 = 0.947$ ), con una mejora respecto a configuraciones menos profundas.

Sin embargo, al analizar los resultados en el conjunto de prueba, se observa una reducción generalizada del desempeño en todos los modelos, lo cual es esperable debido al carácter no lineal del problema y a la limitada cantidad de datos disponibles. En este escenario, el modelo ANN\_Wide



alcanza el mejor equilibrio entre precisión y generalización, registrando el mayor  $R^2$  (0.840), el menor RMSE (1.268) y los valores más bajos de MAPE (12.54 %) y MARD (0.125) entre los modelos evaluados. Resultados similares, aunque ligeramente inferiores, son obtenidos por ANN\_Medium y ANN\_Two\_Layer, con  $R^2$  de 0.835 y 0.830, respectivamente.

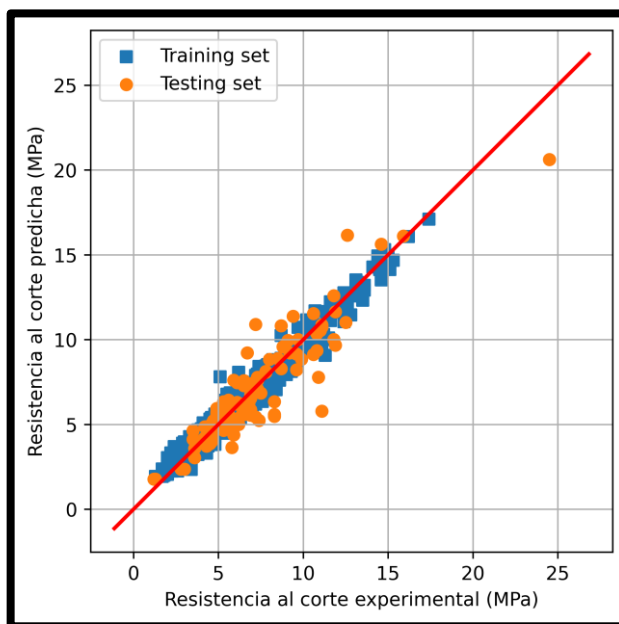
Por el contrario, el modelo ANN\_Three\_Layer, a pesar de su buen desempeño durante el entrenamiento, presenta una caída más pronunciada en la fase de prueba ( $R^2 = 0.794$  y  $RMSE = 1.442$ ), lo que sugiere un mayor grado de sobreajuste, asociado al incremento innecesario de complejidad arquitectónica. Este comportamiento confirma que una mayor profundidad de la red no garantiza necesariamente una mejor capacidad predictiva cuando el tamaño del dataset es limitado.

En términos de robustez, la métrica D10 muestra valores inferiores al 11 % para todos los modelos en la fase de prueba, destacando nuevamente ANN\_Three\_Layer y ANN\_Two\_Layer con los menores porcentajes, lo que indica una proporción relativamente baja de predicciones con errores elevados. No obstante, al considerar simultáneamente todas las métricas, el modelo ANN\_Wide se consolida como la alternativa más consistente y confiable (Figura 26) para el dataset 1.

**Tabla 21 — Métricas de desempeño de modelos ANN optimizados para el dataset 1**

Modelos	Sets	Métricas					
		$R^2$	RMSE	MAE	MAPE (%)	MARD	D <sub>10%</sub>
ANN_Medium	Training	0.939	0.716	0.547	9.93	0.099	7.25
	Testing	0.835	1.29	0.95	14.73	0.147	10.78
ANN_Narrow	Training	0.897	0.931	0.712	13.1	0.131	13.08
	Testing	0.811	1.379	0.993	15.27	0.153	11.82
ANN_Three_Layer	Training	0.947	0.663	0.518	9.36	0.094	9.04
	Testing	0.794	1.442	0.99	14.74	0.147	6.37
ANN_Two_Layer	Training	0.970	0.501	0.371	6.68	0.067	4.54
	Testing	0.830	1.306	0.877	12.84	0.128	9.21
ANN_Wide	Training	0.966	0.531	0.393	7.25	0.072	4.80
	Testing	0.840	1.268	0.873	12.54	0.125	10.18





**Figura 26 — Resultado de la resistencia al corte predicho por el modelo ANN\_Wide optimizado para el dataset 1**

La Tabla 22 presenta las métricas de desempeño final de los modelos de redes neuronales artificiales (ANN) optimizados para el dataset 2, considerando cinco arquitecturas con distinta complejidad: Narrow (10 neuronas), Medium (25 neuronas), Wide (100 neuronas), Two\_Layer (50–25) y Three\_Layer (50–25–10), todas implementadas mediante el algoritmo MLPRegressor con función de activación ReLU y optimizador Adam.

En la fase de entrenamiento, el modelo ANN\_Three\_Layer exhibe el mejor ajuste global, alcanzando un coeficiente de determinación muy elevado ( $R^2 = 0.984$ ) y errores notablemente reducidos (RMSE = 0.37, MAE = 0.263, MAPE = 4.76 %). Este comportamiento refleja la alta capacidad de representación de las arquitecturas profundas, capaces de capturar relaciones no lineales complejas presentes en el dataset. De manera consistente, los modelos ANN\_Wide y ANN\_Medium también muestran un desempeño sólido en entrenamiento, con  $R^2$  superiores a 0.95 y errores relativamente bajos.

No obstante, al evaluar los resultados en el conjunto de prueba, se observa una disminución generalizada del desempeño para todas las arquitecturas, siendo más pronunciada en los modelos de mayor profundidad. En particular, el modelo ANN\_Three\_Layer, pese a su excelente ajuste durante el entrenamiento, presenta una caída significativa en la capacidad predictiva ( $R^2 = 0.791$ ;  $RMSE = 1.258$ ), lo que evidencia un marcado sobreajuste inducido por el incremento de complejidad arquitectónica respecto al tamaño efectivo del dataset.


Entre los modelos evaluados, ANN\_Medium (Figura 27), con una única capa oculta de 25 neuronas, alcanza el mejor desempeño en la fase de prueba, registrando el mayor  $R^2$  (0.839) y el menor RMSE (1.104), junto con valores competitivos de MAE (0.859), MAPE (14.52 %) y MARD (0.145). Este resultado sugiere que una arquitectura de complejidad intermedia logra un balance óptimo entre capacidad de aprendizaje y generalización.

El modelo ANN\_Narrow muestra un comportamiento estable pero limitado por su menor capacidad representativa, mientras que ANN\_Wide y ANN\_Two\_Layer, a pesar de presentar un buen ajuste en entrenamiento, no logran mejorar el desempeño en prueba, confirmando que el aumento del número de neuronas o capas no garantiza necesariamente una mayor precisión predictiva.

En términos de robustez, la métrica D10 revela que los modelos ANN\_Medium y ANN\_Wide mantienen porcentajes moderados de predicciones con errores elevados en el conjunto de prueba ( $\approx 11\%$ ), mientras que ANN\_Two\_Layer presenta el peor desempeño (17.26 %), reforzando la evidencia de una generalización menos estable.

**Tabla 22 — Métricas de desempeño de modelos ANN optimizados para el dataset 2**

Modelos	Sets	Métricas					
		R <sup>2</sup>	RMSE	MAE	MAPE (%)	MARD	D <sub>10%</sub>
ANN_Medium	Training	0.947	0.668	0.507	9.63	0.096	7.58
	Testing	0.839	1.104	0.859	14.52	0.145	11.11
ANN_Narrow	Training	0.910	0.869	0.672	12.68	0.127	9.85
	Testing	0.825	1.151	0.866	14.44	0.144	13.71
ANN_Three_Layer	Training	0.984	0.37	0.263	4.76	0.048	2.87
	Testing	0.791	1.258	0.911	14.25	0.142	13.02
ANN_Two_Layer	Training	0.943	0.697	0.524	8.51	0.085	6.37
	Testing	0.795	1.245	0.999	15.61	0.156	17.26
ANN_Wide	Training	0.959	0.591	0.452	8.34	0.083	5.68
	Testing	0.810	1.209	0.90	14.58	0.146	11.16



**Figura 27 — Resultado de la resistencia al corte predicho por el modelo ANN\_Medium optimizado para el dataset 2**

La Tabla 23 resume las métricas de desempeño final de los modelos de redes neuronales artificiales (ANN) optimizados para el dataset 3. Durante la fase de entrenamiento, los modelos ANN\_Two\_Layer y ANN\_Three\_Layer alcanzan los niveles más altos de ajuste, con coeficientes de determinación R<sup>2</sup> de 0.983 y 0.973, respectivamente, acompañados de errores notablemente bajos (RMSE ≤ 0.48 y MAE ≤ 0.35). Estos resultados confirman que las arquitecturas profundas poseen una elevada capacidad para capturar relaciones no lineales complejas



presentes en el dataset 3. De forma consistente, el modelo ANN\_Wide también muestra un desempeño destacado en entrenamiento ( $R^2 = 0.969$ ), mientras que ANN\_Medium y ANN\_Narrow presentan valores más moderados.

Sin embargo, en la etapa de prueba (testing), se observa nuevamente una disminución del desempeño predictivo en todas las arquitecturas, siendo más pronunciada en los modelos con mayor número de capas. En particular, ANN\_Two\_Layer y ANN\_Three\_Layer, a pesar de su excelente ajuste en entrenamiento, exhiben los valores más bajos de  $R^2$  en prueba (0.770 y 0.815, respectivamente) y los mayores errores ( $RMSE \geq 1.307$ ) en comparación con los valores de entrenamiento ( $RMSE \leq 0.482$ ), lo que evidencia un sobreajuste (Overfitting), esto demuestra que las redes neuronales antes mencionadas presentan una alta capacidad de ajuste sobre el conjunto de entrenamiento, pero no predice bien las resistencias al corte en la unión viga-columna (datos nuevos/datos de salida de la RNA).


En contraste, los modelos de una sola capa oculta muestran un comportamiento más equilibrado. El modelo ANN\_Narrow alcanza el mayor  $R^2$  en prueba (0.832) y uno de los menores RMSE (1.244), mientras que ANN\_Medium presenta resultados muy cercanos ( $R^2 = 0.827$ ;  $RMSE = 1.265$ ). El modelo ANN\_Wide, aunque dispone de una mayor capacidad, no logra mejoras sustanciales respecto a estas arquitecturas más simples, confirmando que el incremento del número de neuronas no se traduce necesariamente en una mejor generalización.

El análisis de la métrica  $D_{10\%}$  refuerza estas observaciones: los modelos profundos presentan los porcentajes más elevados de predicciones cuyo error relativo es menor o igual al 10% en el conjunto de prueba (testing) como es el caso del modelo de la RNA ANN\_Three\_Layer con un valor de  $D_{10\%} = 17.38\%$ . Por el contrario, ANN\_Medium registra el menor  $D_{10\%} = 9.78\%$ , lo que sugiere que el modelo tiene mayor precisión práctica al predecir la resistencia al corte en la unión viga – columna.



**Tabla 23 — Métricas de desempeño de modelos ANN optimizados para el dataset 3**

Modelos	Sets	Métricas					
		R <sup>2</sup>	RMSE	MAE	MAPE (%)	MARD	D <sub>10%</sub>
ANN_Medium	Training	0.922	0.826	0.632	11.39	0.114	8.67
	Testing	0.827	1.265	0.924	14.75	0.147	9.78
ANN_Narrow	Training	0.882	1.015	0.784	14.18	0.142	11.68
	Testing	0.832	1.244	0.911	15.44	0.154	12.97
ANN_Three_Layer	Training	0.973	0.482	0.345	6.46	0.065	4.74
	Testing	0.815	1.307	0.968	15.23	0.152	17.38
ANN_Two_Layer	Training	0.983	0.389	0.283	5.21	0.052	3.25
	Testing	0.770	1.459	1.017	15.09	0.151	13.42
ANN_Wide	Training	0.969	0.518	0.39	7.31	0.073	5.35
	Testing	0.821	1.286	0.897	13.79	0.138	13.56



**Figura 28 — Resultado de la resistencia al corte predicho por el modelo ANN\_Wide optimizado para el dataset 3**

#### 5.1.4 Explicabilidad de los modelos predictivos

Los modelos basados en árboles tienen la limitación de ser difíciles de explicar debido a los muchos hiperparámetros involucrados al hacer una predicción. La técnica SHAP se utiliza para explicar y evaluar la importancia de diferentes características en las predicciones finales, proporcionando explicabilidad local y global (Feng et al. 2021b).



#### 5.1.4.1 Explicabilidad global

La Figura 29 presenta la explicación global del modelo CatBoost entrenado con el dataset 1, utilizando la metodología SHAP (SHapley Additive exPlanations), la cual permite cuantificar la contribución individual de cada variable predictora sobre la estimación de la resistencia al corte experimental  $\tau_{exp}$ .

La Figura 29 (a) muestra la importancia promedio de las características, medida como el valor medio absoluto de SHAP. Este indicador refleja el impacto relativo de cada variable en la magnitud de la salida del modelo.

Los resultados evidencian que:

- El tipo de unión (JT) es la variable más influyente, indicando que la condición interior o exterior de la unión juega un papel determinante en la resistencia al corte.
- Las cuantías de refuerzo y la resistencia del concreto, particularmente  $\rho_b f'_c$ ,  $\rho_c f'_c$  y  $\rho_{jt} f'_c$ , presentan una alta contribución, lo que confirma la importancia combinada de la cantidad de acero y la calidad del concreto en el comportamiento resistente de la unión.
- Las resistencias a fluencia del acero ( $f_{yb}$ ,  $f_{yjt}$ ,  $f_{yc}$ ) tienen una influencia moderada, mientras que las relaciones geométricas ( $h_c/h_b$ ,  $b_c/b_b$ ) y el factor de carga axial (ALF) muestran un impacto comparativamente menor.

La Figura 29 (b) presenta el gráfico resumen de SHAP, donde cada punto representa una observación del dataset. El eje horizontal indica el valor SHAP, es decir, el efecto de cada variable sobre la predicción de  $\tau_{exp}$ , mientras que el color del punto refleja la magnitud del valor de la característica (azul = bajo, rojo = alto).

Del análisis se observa que:

- Valores altos de  $JT$  y de las cuantías de refuerzo tienden a generar contribuciones positivas sobre la resistencia al corte, incrementando el valor predicho de  $\tau_{exp}$ .
- Un aumento en la resistencia a compresión del concreto y en las resistencias a fluencia del acero también está asociado, en general, con efectos positivos sobre la respuesta del modelo.
- La dispersión horizontal de los puntos indica la variabilidad del impacto de cada variable según el contexto estructural, lo que resalta la capacidad del modelo para capturar interacciones no lineales entre parámetros.

El análisis SHAP confirma que el modelo CatBoost no solo presenta un buen desempeño predictivo, sino que además aprende relaciones físicamente interpretables, alineadas con los principios del diseño y comportamiento estructural de las uniones viga-columna de concreto armado.




Figura 29 — Explicación global del modelo CatBoost para el dataset 1 mediante (a) Importancia de características y (b) Gráfico resumen de SHAP

Con el fin de analizar cómo el modelo CatBoost responde a variaciones individuales de las variables más influyentes, se evaluaron los gráficos de dependencia SHAP. Estos gráficos muestran la relación entre el valor de una característica (eje horizontal) y su contribución a la predicción de la resistencia al corte (valor SHAP, eje vertical). Adicionalmente, el color de los puntos representa el valor de una segunda variable, lo que permite identificar posibles efectos de interacción. La Figura 30 presenta los resultados correspondientes a cuatro variables relevantes: (a)  $\rho_b f'_c$ , (b)  $\rho_c f'_c$ , (c)  $\rho_{jt} f'_c$  y (d)  $f_{yb}$ .

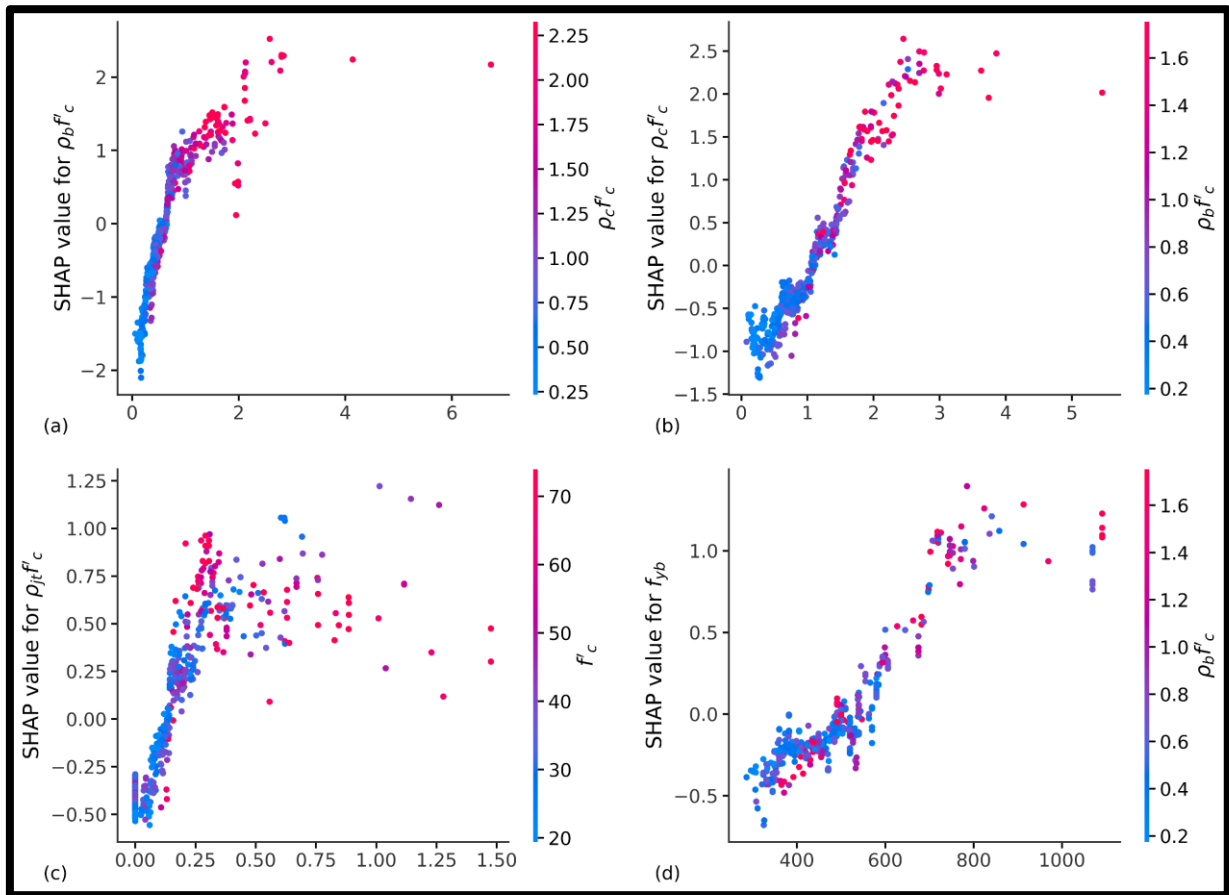
En la Figura 30 (a) se observa que la contribución de  $\rho_b f'_c$  a la resistencia al corte es no lineal. Para valores bajos de esta variable, los valores SHAP son cercanos a cero o negativos, lo que indica una contribución limitada del refuerzo de la viga. A medida que  $\rho_b f'_c$  aumenta, los valores SHAP se vuelven progresivamente positivos, evidenciando un incremento sostenido en la resistencia al corte predicha por el modelo. La dispersión de los puntos, junto con el gradiente de color asociado a  $\rho_c f'_c$ , sugiere que el efecto positivo del refuerzo de la viga es mayor cuando la cuantía de refuerzo de la columna también es elevada. Esto indica una interacción favorable entre ambos refuerzos, coherente con el comportamiento conjunto de la unión viga-columna.

La Figura 30 (b) muestra una tendencia claramente creciente entre  $\rho_c f'_c$  y los valores SHAP. Valores bajos de esta variable generan contribuciones negativas o poco significativas, mientras que valores más altos producen contribuciones positivas importantes a la resistencia al corte. El color de los puntos, correspondiente a  $\rho_b f'_c$ , evidencia que la contribución del refuerzo de la columna es mayor cuando la viga también presenta mayores cuantías de refuerzo. Esto refuerza la idea de que la capacidad resistente de la unión depende del balance entre el refuerzo de la viga y de la columna, más que del efecto aislado de uno solo.

En la Figura 30 (c) se observa que  $\rho_{jt} f'_c$  presenta una contribución positiva marcada para valores bajos y moderados. Sin embargo, a partir de cierto



nivel, el incremento de los valores SHAP tiende a estabilizarse, lo que indica que aumentos adicionales del refuerzo transversal producen beneficios marginales reducidos en la resistencia al corte. El gradiente de color, asociado a la resistencia del concreto  $f'_c$ , muestra que la contribución del refuerzo transversal es más efectiva en especímenes con concreto de mayor resistencia, lo cual es consistente con los mecanismos de confinamiento y control de fisuración en la zona de la unión. Finalmente, la Figura 30 (d) evidencia una relación positiva casi monótona entre la resistencia a fluencia del acero de la viga  $f_{yb}$  y los valores SHAP. A medida que  $f_{yb}$  aumenta, la contribución a la resistencia al corte predicho por el modelo se incrementa de manera progresiva. El color de los puntos, correspondiente a  $\rho_b f'_c$ , indica que el efecto beneficioso de un acero de mayor resistencia es más pronunciado cuando se combina con mayores cuantías de refuerzo en la viga. Esto confirma que el modelo captura de forma coherente el efecto combinado de cantidad y resistencia del acero en el comportamiento de la unión.



**Figura 30** — Gráficos de dependencia de características SHAP del modelo CatBoost para el dataset 1 para (a)  $\rho_b f'_c$ , (b)  $\rho_c f'_c$ , (c)  $\rho_{jt} f'_c$  y (d)  $f_{yb}$

La Figura 31 presenta la explicación global del modelo CatBoost entrenado con el Dataset 2, utilizando la metodología SHAP (SHapley Additive exPlanations). Este análisis permite cuantificar tanto la importancia relativa de cada variable como el sentido de su influencia sobre la predicción de la resistencia al corte experimental de la junta,  $\tau_{exp}$ .

El gráfico de barras de la Figura 31 (a) muestra la media del valor absoluto de SHAP, que representa el impacto promedio de cada variable en la salida del modelo. Se observa que:

- El tipo de junta (JT) es la variable más influyente del modelo, indicando que la configuración geométrica y estructural de la junta domina el comportamiento resistente al corte.


- Las variables de interacción refuerzo–concreto, particularmente  $\rho_c f'_c$ ,  $\rho_b f'_c$  y  $\rho_{jt} f'_c$ , presentan una contribución significativa, lo que confirma la fuerte dependencia de la resistencia al corte respecto a la cuantía de refuerzo y la resistencia del concreto.
- Las interacciones acero–refuerzo en viga y columna ( $f_{yb} \rho_b$  y  $f_{yc} \rho_c$ ) también muestran una influencia relevante, evidenciando la importancia del aporte mecánico del acero.
- Las variables geométricas ( $b_c/b_b$ ,  $h_c/h_b$ ) y el factor de carga axial (ALF) tienen una influencia menor, aunque no despreciable, en la respuesta del modelo.

En conjunto, estos resultados indican que el modelo prioriza variables que representan mecanismos físicos dominantes, como el confinamiento, la transferencia de esfuerzos y la tipología estructural de la unión.

La Figura 31 (b) muestra el gráfico resumen de SHAP, donde cada punto representa una muestra del dataset. El eje horizontal indica el impacto de la variable sobre la predicción de  $\tau_{exp}$ , mientras que el color refleja el valor de la característica (azul: bajo, rojo: alto), Se observa que:

- Valores altos de  $\rho_c f'_c$ ,  $\rho_b f'_c$  y  $\rho_{jt} f'_c$  tienden a generar valores SHAP positivos, es decir, incrementan la resistencia al corte predicho.
- El tipo de junta (JT) produce desplazamientos SHAP tanto positivos como negativos, evidenciando que diferentes configuraciones pueden mejorar o reducir la capacidad resistente.
- El factor de carga axial (ALF) presenta una dispersión limitada y valores SHAP cercanos a cero, lo que confirma su menor influencia relativa en el conjunto de datos analizado.

- Las variables geométricas muestran una contribución moderada, con efectos positivos o negativos según la proporción entre viga y columna.




**Figura 31 — Explicación global del modelo CatBoost para el dataset 2 mediante (a) Importancia de características y (b) Gráfico resumen de SHAP.**

La Figura 32 presenta la explicación global del modelo CatBoost entrenado con el dataset 3, esto permite interpretar la importancia global de las variables como los mecanismos que gobiernan la predicción individual de la resistencia al corte experimental  $\tau_{exp}$ .

La Figura 32 indica que el tipo de junta (JT) es la variable con mayor impacto promedio sobre la predicción del modelo. A continuación, destacan la resistencia del concreto  $f_c'$  y las interacciones acero–refuerzo en viga y columna ( $f_{yb} \rho_b$  y  $f_{yc} \rho_c$ ), seguidas por la interacción refuerzo–concreto en la junta  $\rho_{jt} f_c'$ . Las variables geométricas ( $b_c/b_b$ ,  $h_c/h_b$ ) y el factor de carga axial (ALF) presentan una influencia global menor, lo que sugiere que, dentro del rango del dataset, su efecto es secundario frente a las propiedades mecánicas y tipológicas de la junta.

La Figura 32 confirma que valores altos de  $f'_c$ ,  $f_{yb}\rho_b$ ,  $f_{yc}\rho_c$  y  $f_{yjt}$  generan valores SHAP positivos, incrementando la resistencia al corte predicha. En contraste, el tipo de junta (JT) presenta contribuciones positivas o negativas dependiendo de la configuración, lo que explica su elevada dispersión y su alta importancia global.



**Figura 32 — Explicación global del modelo CatBoost para el dataset 3 mediante (a) Importancia de características y (b) Gráfico resumen de SHAP.**

#### 5.1.4.2 Explicabilidad local

Con el fin de complementar el análisis global presentado previamente, se realizó una explicación local del modelo CatBoost utilizando valores SHAP para muestras individuales representativas. La Figura 33 y la Tabla 24 presenta la explicación local del modelo CatBoost entrenado con el dataset 1. La Figura 33 muestra los diagramas correspondientes a dos especímenes experimentales reportados en la literatura: A0 (Adachi et al. 1995) y LVP4 (Alva et al. 2007). Adicionalmente, la Tabla 24 resume cuantitativamente los valores SHAP asociados a cada variable predictora.

Es necesario aclarar que el modelo CaTBoost desarrollado es de regresión (predicción), los valores y/o aportes SHAP tienen una escala logarítmica,

es necesario aclarar que valores positivos SHAP incrementan la resistencia al corte en la unión viga-columna (variable de salida del modelo de ML) y valores negativos lo disminuyen.

Es importante precisar que los valores obtenidos mediante el método SHAP no poseen unidades físicas ni representan coeficientes mecánicos directos asociados a los parámetros estructurales del modelo. Los valores expresan la contribución relativa de cada variable de entrada en la predicción de la resistencia al corte en la unión viga-columna generada por el modelo de ML.

Para el espécimen A0, el modelo predice una resistencia al corte de  $\tau_{predicción} = 10.62$  MPa, valor muy cercano al resultado experimental  $\tau_{experimental} = 10.30$  MPa, lo que evidencia una alta precisión en la estimación. Tal como se observa en la Figura 33 (a), la predicción se construye a partir de un valor base del modelo, al cual se le suman contribuciones positivas y negativas de las variables individuales. De acuerdo con los valores reportados en la Tabla 24, las principales contribuciones positivas corresponden a la cuantía de refuerzo de la columna  $\rho_c f'_c$ , con un valor SHAP de +1.527, la cuantía de refuerzo de la viga  $\rho_b f'_c$ , con un valor SHAP de +1.212, las resistencias a fluencia del acero, específicamente:  $f_{yb}$  con +0.936,  $f_{yjt}$  con +0.752,  $f_{yc}$  con +0.646 y la cuantía de refuerzo transversal  $\rho_{jt} f'_c$ , con +0.528. Estas variables incrementan significativamente la predicción de  $\tau_{exp}$ , lo cual es consistente con el elevado nivel de refuerzo y la alta capacidad resistente del espécimen A0. Por el contrario, el tipo de unión ( $JT = 0$ , unión exterior) presenta una contribución negativa relevante, con un valor SHAP de -0.851, reduciendo el valor predicho, lo que concuerda con el comportamiento menos favorable de las uniones exteriores frente a las interiores. Asimismo, la relación geométrica  $h_c/h_b$  (-0.282), la resistencia del concreto  $f'_c$  (-0.255) y el factor de carga axial ALF (-0.192) generan contribuciones negativas de menor magnitud.



En el caso del espécimen LVP4, el modelo predice una resistencia al corte de  $\tau_{predicción} = 5.54$  MPa, en excelente concordancia con el valor experimental de  $\tau_{experimental} = 5.50$  MPa. Según la Figura 33 (b) y los valores SHAP de la Tabla 24, las contribuciones positivas más relevantes provienen de la cuantía de refuerzo de la viga  $\rho_b f'_c$ , con un valor SHAP de +0.346, la resistencia a fluencia del refuerzo de la viga  $f_{yb}$ , con +0.350 y la resistencia a compresión del concreto  $f'_c$ , con una contribución moderada de +0.080. Sin embargo, a diferencia del caso anterior, se observa que la cuantía de refuerzo de la columna  $\rho_c f'_c$  y el tipo de unión ( $JT = 0$ ) generan contribuciones negativas, con valores SHAP de  $-0.349$  y  $-0.796$ , respectivamente, lo que explica el menor nivel de resistencia al corte del espécimen LVP4. Las variables geométricas  $b_c/b_b$  ( $-0.105$ ),  $h_c/h_b$  ( $-0.009$ ) y el factor de carga axial ALF ( $-0.053$ ) presentan efectos marginales sobre la predicción final.

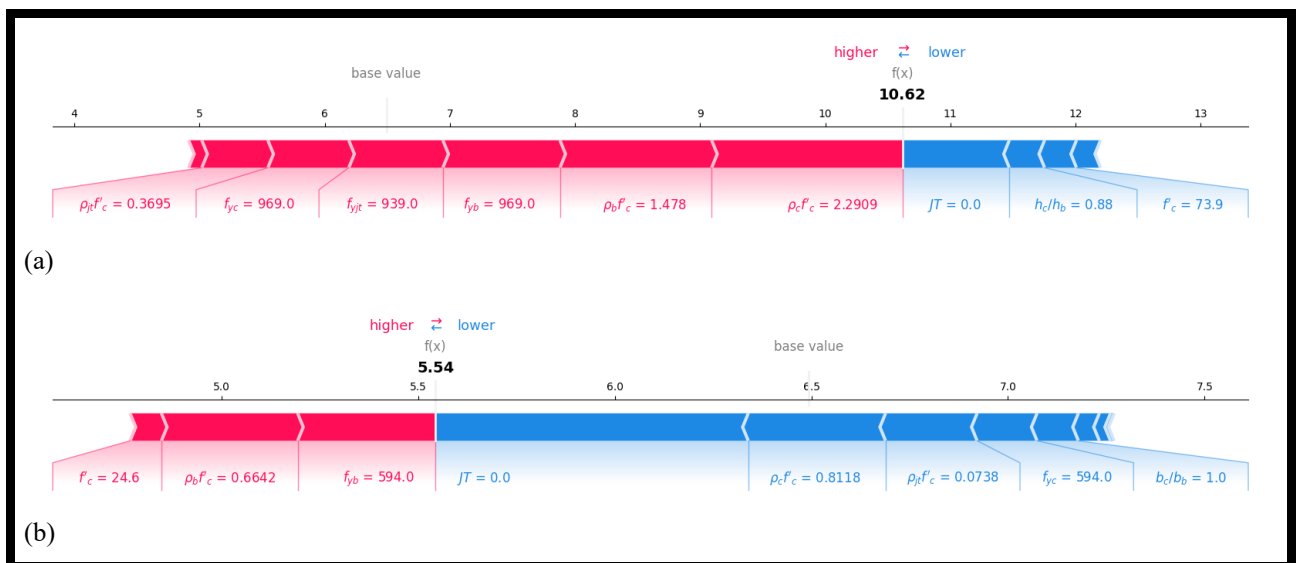


Figura 33 — Explicación local del modelo CatBoost para el dataset 1 mediante valores SHAP de los especímenes seleccionados: (a) espécimen A0 de Adachi et al. (1995); y (b) espécimen LVP4 de Alva et al. (2007).

**Tabla 24 — Valores SHAP del modelo CatBoost para el dataset 1 para la explicación local de los especímenes seleccionados**

Especímen	$\tau_{predicción}$	$\tau_{experimental}$	SHAP values										
			$b_c/b_b$	$h_c/h_b$	$f'_c$	$\rho_{jt}f'_c$	$\rho_b f'_c$	$\rho_c f'_c$	$f_{yjt}$	$f_{yb}$	$f_{yc}$	JT	ALF
A0	10.62	10.3	0.105	-0.282	-0.255	0.528	1.212	1.527	0.752	0.936	0.646	-0.851	-0.192
LVP4	5.544	5.5	-0.105	-0.009	0.08	-0.233	0.346	-0.349	-0.028	0.35	-0.152	-0.796	-0.053

La Figura 34 y la Tabla 25 presenta la explicación local del modelo CatBoost entrenado con el Dataset 2, para el espécimen A0, el modelo predice una resistencia  $\tau_{predicción} = 10.54$ , muy cercana al valor experimental  $\tau_{experimental} = 10.30$ . La Tabla 25 muestra que esta predicción está dominada por las variables de interacción refuerzo–concreto (con valores adimensionales positivos)  $\rho_c f'_c = +1.319$ ,  $\rho_b f'_c = +0.840$  y  $\rho_{jt} f'_c = +0.737$ . Estas contribuciones positivas explican el incremento en la resistencia al corte (variable de salida del modelo de ML). Asimismo, las interacciones acero–refuerzo aportan adicionalmente  $f_{yb} \rho_b = +0.667$  y  $f_{yc} \rho_c = +0.521$ . Por el contrario, el tipo de junta (JT) presenta una contribución negativa ( $-0.911$ ), indicando que la configuración geométrica de la junta tiende a reducir la resistencia; sin embargo, este efecto es compensado por la alta contribución de las variables mecánicas.

Para el espécimen LVP4, la resistencia predicha ( $\tau_{predicción} = 5.64$ ) también concuerda con el valor experimental ( $\tau_{experimental} = 5.50$ ). En este caso, la Tabla 25 evidencia un predominio de contribuciones negativas asociadas al concreto y al refuerzo  $f'_c = -0.369$ ,  $\rho_{jt} f'_c = -0.386$  y  $\rho_c f'_c = -0.261$ . Estas contribuciones negativas explican la menor capacidad resistente estimada por el modelo. No obstante, el aporte positivo del acero en viga y columna  $f_{yb} \rho_b = +0.594$ , y  $f_{yc} \rho_c = +0.609$  compensa parcialmente la pérdida de resistencia, evitando una subestimación excesiva. El tipo de junta (JT) vuelve a presentar una contribución negativa significativa ( $-0.808$ ), consistente con lo observado en el espécimen A0 y con la importancia global mostrada en la Figura 31 (a).



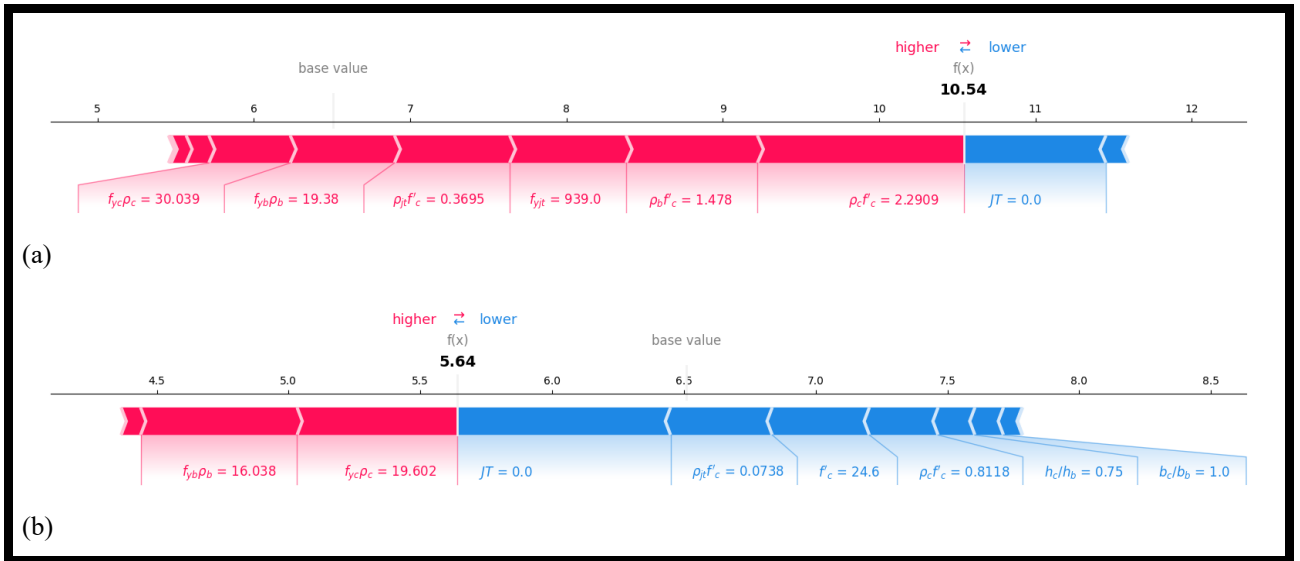


Figura 34 — Explicación local del modelo CatBoost para el dataset 2 mediante valores SHAP de los especímenes seleccionados: (a) espécimen A0 de Adachi et al. (1995); y (b) espécimen LVP4 de Alva et al. (2007).

Tabla 25 — Valores SHAP del modelo CatBoost para el dataset 2 para la explicación local de los especímenes seleccionados

Especímen	$\tau_{predicción}$	$\tau_{experimental}$	SHAP values										
			$b_c/b_b$	$h_c/h_b$	$f'_c$	$\rho_{jt}f'_c$	$\rho_b f'_c$	$\rho_c f'_c$	$f_{yjt}$	$f_{yb}\rho_b$	$f_{yc}\rho_c$	$JT$	$ALF$
A0	10.54	10.3	0.145	-0.144	0.096	0.737	0.84	1.319	0.745	0.667	0.521	-0.911	0.018
LVP4	5.641	5.5	-0.108	-0.14	-0.369	-0.386	0.074	-0.261	-0.002	0.594	0.609	-0.808	-0.071

La Figura 35 y la Tabla 26 presenta la explicación local del modelo CatBoost entrenado con el Dataset 3, para el espécimen A0, el modelo predice  $\tau_{predicción} = 10.317$ , en excelente concordancia con el valor experimental  $\tau_{experimental} = 10.3$ . La Tabla 26 muestra que esta predicción está principalmente sustentada por contribuciones positivas asociadas a las propiedades mecánicas, resistencia del concreto  $f'_c = +1.308$ , resistencia del acero en la junta:  $f_{yjt} = +1.121$ , interacción acero–refuerzo en viga  $f_{yb}\rho_b = +0.907$ , interacción acero–refuerzo en columna  $f_{yc}\rho_c = +0.893$  y la interacción refuerzo–concreto en la junta  $\rho_{jt}f'_c = +0.592$ . Estas contribuciones positivas explican el elevado valor de resistencia al corte estimado. En contraste, el tipo de junta (JT) presenta una contribución negativa significativa ( $-1.039$ ), indicando que la



configuración geométrica tiende a reducir la resistencia; sin embargo, este efecto es ampliamente compensado por la alta capacidad mecánica de los materiales. El factor de carga axial (ALF) tiene una contribución prácticamente nula ( $-0.001$ ), confirmando su escasa influencia en esta muestra.

Para el espécimen LVP4, la resistencia predicha ( $\tau_{predicción} = 5.557$ ) reproduce adecuadamente el valor experimental ( $\tau_{experimental} = 5.5$ ). En este caso, la Tabla 26 evidencia una combinación de efectos desfavorables y compensatorios:

- Contribuciones negativas dominantes:  $f'_c = -1.065$ ,  $\rho_{jt}f'_c = -0.599$  lo que refleja una menor capacidad resistente asociada al concreto y a la transferencia de esfuerzos en la junta.
- Contribuciones positivas del acero:  $f_{yb}\rho_b = +0.672$ ,  $f_{yc}\rho_c = +1.011$  que compensan parcialmente la pérdida de resistencia.

El tipo de junta (JT) vuelve a presentar una contribución negativa importante ( $-0.859$ ), coherente con su alta importancia global mostrada en la Figura 32 (a).

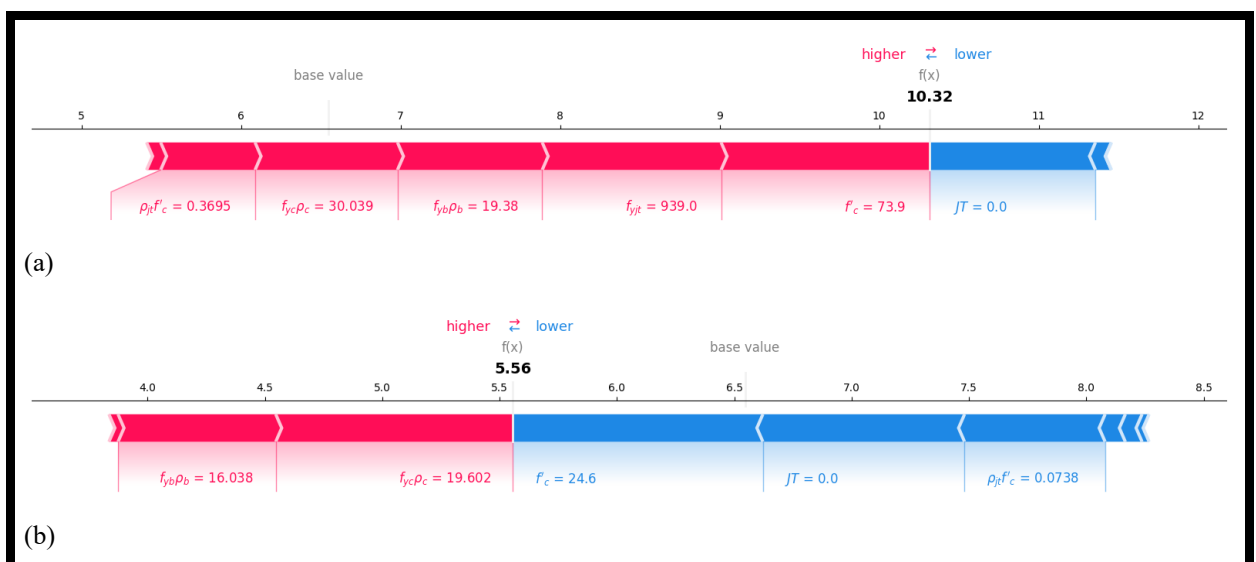


Figura 35 — Explicación local del modelo CatBoost para el dataset 3 mediante valores SHAP de los especímenes seleccionados: (a) espécimen A0 de Adachi et al. (1995); y (b) espécimen LVP4 de Alva et al. (2007).



**Tabla 26 — Valores SHAP del modelo CatBoost para el dataset 3 para la explicación local de los especímenes seleccionados**

Especímen	$\tau_{prediccion}$	$\tau_{experimental}$	SHAP values								
			$b_c / b_b$	$h_c / h_b$	$f'_c$	$\rho_{jt}f'_c$	$f_{yjt}$	$f_{yb}\rho_b$	$f_{yc}\rho_c$	$JT$	$ALF$
A0	10.317	10.3	0.088	-0.099	1.308	0.592	1.121	0.907	0.893	-1.039	-0.001
LVP4	5.557	5.5	-0.03	-0.086	-1.065	-0.599	0.039	0.672	1.011	-0.859	-0.071

## 5.2 Discusión

### 5.2.1 Comparación del desempeño entre enfoques de modelado

De acuerdo con las Tablas 5, 6 y 7, los modelos de Ensemble Learning presentan de manera consistente los mayores valores de  $R^2$  y los menores errores RMSE y MARD en los tres datasets evaluados. En particular, el modelo CatBoost alcanza valores de  $R^2$  de 0.86, 0.86 y 0.87 para los Datasets 1, 2 y 3, respectivamente, con errores RMSE cercanos a 1.0 MPa y desviaciones estándar reducidas. Este comportamiento indica una elevada capacidad de generalización bajo validación cruzada, superior a la observada en los modelos SVM y ANN. En contraste, el modelo AdaBoost muestra los menores valores de  $R^2$  y los mayores errores en los tres conjuntos de datos (Tablas 5–7), lo que evidencia una menor robustez frente a la variabilidad experimental. Este resultado sugiere que los enfoques de boosting más simples presentan limitaciones para capturar la complejidad no lineal del mecanismo resistente de la unión viga–columna.

Los modelos SVM (Tablas 8–10) presentan un desempeño intermedio. Los modelos con kernel lineal exhiben los peores resultados, con valores de  $R^2$  inferiores a 0.80 y altos valores de  $D_{10}\%$ , lo que confirma que la relación entre las variables predictoras y la resistencia al corte no puede representarse adecuadamente mediante un modelo lineal. La incorporación de kernels no lineales mejora el desempeño; sin embargo, incluso los mejores modelos SVM no alcanzan los niveles de precisión ni la estabilidad mostrados por los modelos ensemble, particularmente en términos de dispersión de los errores.

Por su parte, los modelos de Redes Neuronales Artificiales (ANN) (Tablas 11–13) muestran un comportamiento dependiente del dataset y de la arquitectura empleada. En el Dataset 1, las ANN presentan valores bajos de  $R^2$  y errores



elevados, lo que indica dificultades de generalización. En los Datasets 2 y 3, las arquitecturas de complejidad moderada (Medium y Wide NN) alcanzan valores de  $R^2$  comparables a los modelos SVM; sin embargo, las desviaciones estándar siguen siendo superiores a las observadas en los modelos ensemble. Asimismo, el incremento del número de capas no conduce a mejoras, lo que sugiere posibles problemas de sobreajuste y limitaciones asociadas al tamaño del conjunto de datos.

### 5.2.2 Comparación del desempeño predictivo global

El desempeño de los modelos optimizados se evalúa comparando directamente las métricas de testing reportadas en las Tablas 15–17 (Ensemble), 18–20 (SVM) y 21–23 (ANN).

- Para el Dataset 3, los modelos CatBoost y Random Forest alcanzan los mayores valores de  $R^2$  en testing, 0.893 y 0.896 respectivamente (Tabla 17), con errores RMSE inferiores a 1.0 MPa, lo que representa el mejor desempeño global entre todos los modelos evaluados.
- En contraste, el modelo SVM optimizado alcanza un  $R^2 = 0.846$  en el mismo dataset (Tabla 20), con un RMSE mayor (1.193 MPa), evidenciando una menor capacidad predictiva.
- El modelo ANN optimizado logra un  $R^2 = 0.821$  en testing para el Dataset 3 (Tabla 23), con un RMSE de 1.286 MPa, ubicándose por debajo de los modelos ensemble.

Esta jerarquía de desempeño confirma que los modelos ensemble son los más adecuados para capturar la complejidad del problema estructural analizado.

### 5.2.3 Análisis del sobreajuste y capacidad de generalización

El sobreajuste se evalúa mediante la diferencia entre métricas de entrenamiento y testing:



- Para los modelos GBRT y XGBoost, se observan valores de  $R^2 > 0.99$  en el entrenamiento (Tablas 15–17), pero una reducción moderada en testing ( $R^2 \approx 0.86–0.88$ ), lo que indica sobreajuste controlado.
- Para el modelo SVM – Dataset 1, el  $R^2$  cae de 0.944 en entrenamiento a 0.562 en testing (Tabla 18), mostrando un sobreajuste severo, lo que sugiere que el modelo es altamente sensible a la distribución de los datos y a la selección de variables.
- Para el modelo ANN, la caída es de aproximadamente 0.13–0.15 en  $R^2$  (Tablas 21–23), indicando una generalización intermedia.

Desde una perspectiva física, este comportamiento es consistente con la naturaleza del problema: la resistencia al corte en uniones viga–columna depende de múltiples mecanismos no lineales e interacciones entre variables, las cuales son más eficazmente capturadas por modelos basados en ensambles de árboles.

#### 5.2.4 Influencia del diseño del dataset

La evolución del desempeño entre datasets muestra una relación directa con la coherencia mecánica de las variables:

- El Dataset 1, con un mayor número de variables e interacciones, ofrece buena capacidad predictiva, pero introduce redundancia, presenta mayores errores y sobreajuste, especialmente en el modelo SVM (Tabla 18).
- El Dataset 2 mejora la representación física al incorporar interacciones acero–refuerzo más directas, lo que reduce errores en ANN y SVM.
- El Dataset 3, que incluye únicamente relaciones geométricas, propiedades mecánicas efectivas del refuerzo y el efecto de la carga axial, produce los menores errores de testing en modelos ensemble (Tabla 17).

Este resultado demuestra que una ingeniería de características basada en criterios estructurales puede ser tan importante como la elección del algoritmo de Machine Learning.

### 5.2.5 Explicabilidad global y local (SHAP)

La explicabilidad global del modelo CatBoost, mostrada en la Figura 32(a), permite sustentar cuantitativamente que la variable JT es el factor más influyente en la predicción de la resistencia al corte en la unión viga–columna, con un valor medio de impacto SHAP aproximado de 1.05, superando en alrededor de 60 % al impacto del concreto ( $f'_c \approx 0.65$ ). Este resultado evidencia que la tipología estructural de la unión controla el mecanismo resistente predominante, lo cual es plenamente coherente con la mecánica del comportamiento de uniones sometidas a cargas sísmicas. Asimismo, las variables asociadas a la capacidad resistente de los materiales, particularmente  $f'_c$ ,  $f_{yb}\rho_b$  y  $f_{yc}\rho_c$ , presentan impactos medios entre 0.50 y 0.65, confirmando que la resistencia del concreto y la capacidad del acero son determinantes en la resistencia al corte de la unión. El término combinado  $\rho_{jt}f'_c$ , con un impacto medio cercano a 0.45, refuerza la importancia de la interacción entre el confinamiento proporcionado por el refuerzo transversal y la resistencia del concreto, alineándose con los modelos mecánicos de biela–tirante propuestos en la literatura.

Desde una perspectiva local, el análisis SHAP del espécimen A0 en el dataset 3 (Tabla 26) muestra que la elevada resistencia al corte predicha ( $\tau_{pred} = 10.317$ ) está sustentada principalmente en contribuciones positivas del concreto y del refuerzo. En particular,  $f'_c$  aporta +1.308,  $f_{yjt}$  +1.121,  $f_{yb}\rho_b$  +0.907 y  $f_{yc}\rho_c$  +0.893. Estos valores cuantifican que la capacidad resistente del espécimen se origina fundamentalmente en la calidad del material y en la cantidad efectiva de refuerzo, mientras que la tipología de la unión ( $JT = -1.039$ ) introduce una penalización parcial, consistente con un comportamiento menos favorable desde el punto de vista del confinamiento. Esta descomposición confirma que el modelo no atribuye la resistencia a factores geométricos secundarios, sino a mecanismos resistentes físicamente verificables.

En contraste, para el espécimen LVP4, caracterizado por una menor resistencia experimental, el análisis SHAP revela contribuciones negativas dominantes asociadas a  $f'_c = -1.065$ ,  $\rho_{jt}f'_c = -0.599$  y  $JT = -0.859$ . Estos valores indican que la reducción de la resistencia al corte está gobernada por la baja calidad del concreto y por una deficiente capacidad de transferencia de esfuerzos en la zona de la junta, lo cual es coherente con la aparición prematura de fisuración diagonal y la pérdida de capacidad del mecanismo de biela comprimida. La consistencia entre la predicción del modelo y el comportamiento mecánico esperado demuestra que el aprendizaje del modelo está sustentado en principios estructurales reales. La concordancia entre la explicabilidad global y local confirma que el modelo CatBoost prioriza variables con significado físico claro y cuantifica su influencia de manera coherente con la mecánica de las uniones viga–columna. Por tanto, el uso de técnicas SHAP no solo valida el desempeño predictivo del modelo, sino que proporciona una base objetiva para interpretar y justificar sus resultados desde el punto de vista ingenieril.



## CAPÍTULO VI

### CONCLUSIONES Y RECOMENDACIONES

#### 6.1 Conclusiones

- El modelo CatBoost presenta el mejor equilibrio entre precisión y generalización en los tres datasets, de acuerdo con las Tablas 15, 16 y 17, el modelo CatBoost mantiene de forma consistente valores elevados de  $R^2$  en testing (0.84, 0.835 y 0.893 respectivamente), acompañados de menores errores RMSE, MAE, MARD y D10 en comparación con el resto de los modelos. Este comportamiento indica una mayor capacidad de generalización ante la variabilidad de los datos y una mejor capacidad para capturar relaciones no lineales sin incurrir en sobreajuste severo.

Desde una perspectiva estructural, la reducción del RMSE y MAE implica una disminución en la magnitud promedio de la discrepancia entre la resistencia experimental y la resistencia estimada, lo que se traduce en una menor dispersión predictiva y, por ende, en una estimación más precisa de la capacidad resistente de la unión. Paralelamente, la disminución del MARD confirma una mejora en términos de error relativo porcentual, garantizando coherencia predictiva bajo distintos niveles de resistencia del concreto, cuantía de refuerzo transversal y longitudinal, dimensiones geométricas y niveles de carga axial.

El desempeño superior del indicador D10 refleja un mayor porcentaje de predicciones dentro de un margen de error aceptable desde el punto de vista ingenieril, lo cual resulta particularmente relevante en aplicaciones asociadas al diseño sísmico, donde la incertidumbre en la estimación de la resistencia al corte puede influir directamente en la evaluación de mecanismos frágiles de falla.

- El Dataset 3 muestra una mejora clara en la capacidad predictiva y estabilidad estadística de los modelos evaluados. Los resultados del Dataset 3 (Tabla 17) evidencian incrementos en testing alcanzando valores de  $R^2$ : 0.851 en AdaBoost; 0.893 en CatBoost; 0.86 en GBRT; 0.887 en LGBM; 0.896 en RF y 0.878 en XGB,



junto con reducciones notables en RMSE y MARD. Esto confirma que una selección de variables basada en criterios físicos y mecánicos mejora la generalización del modelo al reducir la complejidad innecesaria del espacio de entrada.

la mejora simultánea en  $R^2$  y la reducción en los errores absolutos y relativos indican una menor dispersión entre la resistencia al corte experimental y la resistencia estimada, lo que se traduce en predicciones más consistentes de la capacidad resistente de la unión viga–columna bajo distintas configuraciones geométricas y mecánicas

La disminución del RMSE refleja una reducción en la magnitud promedio del error de estimación, mientras que la reducción del MARD evidencia una mejora en la precisión relativa, particularmente relevante cuando se evalúan especímenes con distintos niveles de resistencia del concreto, cuantías de refuerzo y condiciones de carga axial. En términos prácticos, ello implica una menor incertidumbre en la estimación de la resistencia al corte y una mejor representación de los mecanismos resistentes

- Los modelos Random Forest y LightGBM exhiben un desempeño altamente competitivo cuando el conjunto de variables de entrada se encuentra fundamentado en parámetros con significado físico y mecánico claramente definido. En el Dataset 3, ambos algoritmos alcanzan coeficientes de determinación en testing de  $R^2 = 0.896$  para Random Forest y  $R^2 = 0.887$  para LightGBM (Tabla 17), acompañados de valores de RMSE y MARD comparables a los obtenidos por modelos de boosting de mayor complejidad. Estos resultados indican que la adecuada representación de los mecanismos resistentes al corte incluyendo la contribución del concreto, el confinamiento, la cuantía de refuerzo transversal, la interacción viga–columna y el efecto de la carga axial permite capturar la respuesta resistente de la unión sin necesidad de recurrir a arquitecturas algorítmicas excesivamente complejas.
- La optimización de hiperparámetros mediante búsqueda en cuadrícula (Grid Search), combinada con validación cruzada de cinco pliegues, permitió identificar configuraciones algorítmicas estables y comparables entre los modelos. La aplicación de búsqueda en cuadrícula combinada con validación cruzada de 5

pliegues (Tabla 14) garantizó que los hiperparámetros seleccionados para cada modelo de Ensemble Learning correspondan a configuraciones óptimas desde el punto de vista estadístico, evitando sesgos asociados a particiones específicas del conjunto de datos.

la implementación de validación cruzada garantiza que la capacidad del modelo para predecir la resistencia al corte en la unión viga–columna no esté condicionada por un subconjunto particular de especímenes, sino que refleje un comportamiento consistente ante diferentes combinaciones de propiedades mecánicas, configuraciones geométricas y niveles de carga axial incluidos en la base de datos.

- A partir del análisis comparativo integral de desempeño, se identifica a CatBoost como el modelo óptimo para la predicción de la resistencia al corte en uniones viga–columna. La evaluación simultánea de precisión estadística, estabilidad entre entrenamiento y testing, reducción de errores absolutos y relativos, así como consistencia en los tres datasets analizados, confirma su superioridad frente a los demás algoritmos evaluados. Los elevados coeficientes de determinación obtenidos en la fase de validación, junto con la reducción sistemática de RMSE, MAE, MARD y D10, evidencian una menor dispersión entre los valores experimentales y las estimaciones del modelo. Desde el punto de vista estructural, esto se traduce en una estimación más precisa y estable de la capacidad resistente al corte, reduciendo la incertidumbre asociada a la variabilidad experimental de parámetros como la resistencia del concreto, la cuantía y configuración del refuerzo, las dimensiones geométricas y el nivel de carga axial.
- El análisis de explicabilidad global mediante SHAP confirma la consistencia físico–mecánica del modelo propuesto, al identificar que la tipología de la unión (JT) constituye la variable de mayor contribución en la predicción de la resistencia al corte, seguida por la resistencia a compresión del concreto y la capacidad resistente del acero de refuerzo.

La jerarquización de importancia obtenida no solo refleja el peso estadístico de dichas variables dentro del modelo, sino que resulta plenamente coherente con los mecanismos resistentes establecidos en la teoría clásica del comportamiento de juntas



viga–columna. En particular, la tipología de la unión condiciona la configuración del campo de esfuerzos, influyendo directamente en la formación de bielas de compresión, la eficiencia del confinamiento y la interacción entre la acción del concreto y el refuerzo transversal.

- El análisis de explicabilidad local mediante valores SHAP confirma que las predicciones individuales del modelo se encuentran sustentadas en contribuciones físicas cuantificables y mecánicamente coherentes. La descomposición aditiva de cada estimación permite identificar, para cada espécimen, el peso específico de las variables estructurales en la resistencia al corte predicho, proporcionando trazabilidad técnica a la respuesta del algoritmo.

Esta coherencia entre las contribuciones locales identificadas por SHAP y los mecanismos resistentes establecidos en la teoría clásica de juntas viga–columna demuestra que el modelo no basa sus predicciones en correlaciones estadísticas carentes de significado estructural, sino que internaliza relaciones alineadas con los principios fundamentales de la mecánica del concreto reforzado.

## 6.2 Recomendaciones

- Se recomienda que la aplicación del modelo de Machine Learning propuesto para la predicción de la resistencia al corte en uniones viga–columna se limite estrictamente al dominio paramétrico representado en el Dataset 3, el cual incorpora exclusivamente especímenes correspondientes a nudos interiores y exteriores debidamente caracterizados. En consecuencia, la confiabilidad predictiva del modelo queda garantizada únicamente para estas tipologías estructurales, bajo rangos de variables equivalentes a los considerados en el proceso de entrenamiento.

El modelo fue calibrado a partir de variables con significado físico y mecánico directamente vinculadas a los mecanismos resistentes, incluyendo el tipo de unión (JT), diferenciando explícitamente entre nudos interiores y exteriores, la resistencia a compresión del concreto ( $f'c$ ), las propiedades del acero de la viga ( $f_{yb}, \rho_b$ ) y de la columna ( $f_{yc}, \rho_c$ ), el índice de refuerzo de la unión ( $\rho_{jt}f'c$ ), el límite elástico del acero transversal en la junta ( $f_{yjt}$ ), la relación ancho columna–viga ( $b_c/b_b$ ), el factor de carga axial (ALF) y la relación altura columna–viga ( $h_c/h_b$ ).



- El modelo desarrollado está permitido emplearse como herramienta de predicción de la resistencia al corte en uniones viga–columna, dentro del dominio paramétrico representado en el Dataset 3, para contrastar resultados mediante modelos mecánicos de bielas y tirantes lo que permite identificar posibles subestimaciones o sobreestimaciones, además se debe tener claro, que el modelo de Machine Learning no reemplaza la formulación mecánica, sino que revela factores que no son explícitamente considerados en expresiones mecánicas comunes.
- Para mantener el rigor técnico, no se debe utilizar como sustituto de procedimientos normativos de diseño estructural, no se debe emplear fuera del dominio paramétrico del Dataset 3, no se debe aplicar a tipologías distintas a nudos interiores y exteriores empleados en la base de datos experimental.
- Se recomienda el uso de modelos de Ensemble Learning, particularmente CatBoost, como herramienta de apoyo para la evaluación de la resistencia al corte en uniones viga–columna en contextos de investigación y diseño avanzado.
- Obtener ecuaciones para la predicción de la resistencia al corte en la unión viga–columna, empleando el modelo de Machine Learning CatBoost desarrollado y programación genética.
- En futuras investigaciones, se sugiere ampliar la base de datos experimental, incorporando un mayor rango de configuraciones geométricas, niveles de carga axial y detalles de refuerzo.
- Se recomienda integrar modelos de Machine Learning con expresiones analíticas existentes, con el fin de desarrollar enfoques híbridos que combinen interpretabilidad física y alta precisión predictiva.
- Se sugiere profundizar en el uso de técnicas de interpretabilidad como SHAP para evaluar la coherencia física de las predicciones y facilitar la adopción de estos modelos en la práctica ingenieril.

- La explicabilidad SHAP debe emplearse como criterio de validación física, complementando las métricas estadísticas tradicionales.
- Finalmente, se recomienda explorar el uso de modelos probabilísticos o enfoques de incertidumbre para evaluar la variabilidad inherente a los ensayos experimentales de uniones viga–columna.
- Promover el trabajo colaborativo entre las escuelas profesionales de ingeniería informática y sistemas e ingeniería civil de la UNAMBA.



## REFERENCIAS BIBLIOGRÁFICAS

- BAKIR, P. G.; BODUROĞLU, H. M.** A new design equation for predicting the joint shear strength of monotonically loaded exterior beam-column joints. *Engineering structures*, 2002, vol. 24, no 8, p. 1105-1117.
- BLOSSIERS CRUZ, Marjorie Diana; JACINTO MORALES, Fred Alex.** Análisis de fallas estructurales y comportamiento sísmico en las uniones viga-columna en pórticos de concreto armado. 2020.
- BREIMAN, Leo.** Random forests. *Machine Learning*, 2001, vol. 45, no 1, p. 5-32.
- ESTEGHAMATI, Mohsen Zaker; FLINT, Madeleine M.** Developing data-driven surrogate models for holistic performance-based assessment of mid-rise RC frame buildings at early design. *Engineering Structures*, 2021, vol. 245, p. 112971.
- FERNANDEZ CASTILLO, Solange Lady.** Uso de redes neuronales artificiales en el cálculo de la distorsión de entrepiso en edificaciones de albañilería confinada, Lima-2022. 2023.
- FENG, De-Cheng, et al.** Data-driven approach to predict the plastic hinge length of reinforced concrete columns and its application. *Journal of Structural Engineering*, 2021, vol. 147, no 2, p. 04020332.
- FENG, De-Cheng, et al (a).** Implementing Ensemble Learning methods to predict the shear strength of RC deep beams with/without web reinforcements. *Engineering Structures*, 2021, vol. 235, p. 111979.
- FENG, De-Cheng, et al (b).** Interpretable XGBoost-SHAP Machine-Learning model for shear strength prediction of squat RC walls. *Journal of Structural Engineering*, 2021, vol. 147, no 11, p. 04021173.
- HANSON, Norman W.; CONNOR, Harold W.** Seismic resistance of reinforced concrete beam-column joints. *Journal of the structural Division*, 1967, vol. 93, no 5, p. 533-560.
- HASSAN, Wael M.; MOEHLE, Jack. P.** Seismic vulnerability of corner beam-column joints in existing concrete buildings: An experimental investigation. En *Proceedings*. 2012.
- HASSAN, Wael M.; MOEHLE, Jack P.** Seismic strength models for beam-column joints in existing concrete buildings. En *Proc., 11th Canadian Conf. on Earthquake Engineering*. Vancouver, BC, Canada: Canadian Association of Earthquake Engineering. 2015.
- HASSAN, W.; AL-ZAHRAA REFAIE, F.; BELAL, A.** Seismic vulnerability of concrete beam-column joints in older construction under high axial loads. En *Proceeding of the 16th European Conference on earthquake engineering*. Springer, 2018. p. 1-10.



- HASSAN, Wael Mohammed.** Analytical and experimental assessment of seismic vulnerability of beam-column joints without transverse reinforcement in concrete buildings. University of California, Berkeley, 2011.
- HASSAN, W. M., et al.** Seismic response of older-type reinforced concrete corner joints. En Proceedings of the 9 th US National and 10 th Canadian Conference on Earthquake Engineering. 2010. p. 25-29.
- HARITH, Iman Kattoof, et al.** Machine Learning-based prediction of shear strength in interior beam-column joints. Discover Applied Sciences, 2025, vol. 7, no 5, p. 469.
- HWANG, Shyh-Jiann; LEE, Hung-Jen.** Analytical model for predicting shear strengths of exterior reinforced concrete beam-column joints for seismic resistance. ACI Structural Journal, 1999, vol. 96, p. 846-857.
- KARAYANNIS, Chris G.; CHALIORIS, Constantin E.; SIRKELIS, George M.** Local retrofit of exterior RC beam-column joints using thin RC jackets—An experimental study. Earthquake Engineering & Structural Dynamics, 2008, vol. 37, no 5, p. 727-746.
- KARAMPINIS, Ioannis, et al.** Analytical Equations for the Prediction of the Failure Mode of Reinforced Concrete Beam-Column Joints Based on Interpretable Machine Learning and SHAP Values. Sensors, 2024, vol. 24, no 24, p. 7955.
- KIM, Jaehong; LAFAVE, James M.; SONG, J.** Joint shear behaviour of reinforced concrete beam-column connections. Magazine of concrete research, 2009, vol. 61, no 2, p. 119-132.
- KIM, Jaehong; LAFAVE, James M.** A simplified approach to joint shear behavior prediction of RC beam-column connections. Earthquake Spectra, 2012, vol. 28, no 3, p. 1071-1096.
- KOTSOVOU, Gregoria M.; COTSOVOS, Demitrios M.; LAGAROS, Nikos D.** Assessment of RC exterior beam-column Joints based on artificial neural networks and other methods. Engineering Structures, 2017, vol. 144, p. 1-18.
- LAFAVE, James M.; KIM, Jaehong.** Joint shear behavior prediction for RC beam-column connections. International Journal of Concrete Structures and Materials, 2011, vol. 5, no 1, p. 57-64.
- MANGALATHU, Sujith; JEON, Jong-Su.** Classification of failure mode and prediction of shear strength for reinforced concrete beam-column joints using Machine Learning techniques. Engineering Structures, 2018, vol. 160, p. 85-94.
- MANGALATHU, Sujith, et al.** Data-driven Machine-Learning-based seismic failure mode identification of reinforced concrete shear walls. Engineering Structures, 2020, vol. 208, p. 110331.



**MOLINA RAMIREZ, Alexander; SICHA PILLACA, Juan Carlos.** Diseño estructural de viviendas de albañilería confinada mediante el uso de redes neuronales artificiales en distritos de Lima con perfil de suelo tipo S1. 2021.

**MURPHY, Kevin P.** Machine Learning: a probabilistic perspective. MIT press, 2012.

**PARKER, Daniel Edward; BULLMAN, P. J. M.** Shear strength within reinforced concrete beam-column joints. Structural engineer, 1997, vol. 75, no 4.

**SARSAM, K. F.; PHIPPS, M. E.** The shear design of in situ reinforced concrete beam-column joints subjected to monotonic loading. Magazine of Concrete Research, 1985, vol. 37, no 130, p. 16-28.

**SANCHEZ MAGUIÑA, Mildred Madeleine; VIDAL FELIZ, Pool Rusbel.** Optimización de dimensiones de elementos estructurales mediante el uso de redes neuronales para la reducción de sobrecostos en edificios multifamiliares de 6 pisos ubicado en el distrito de Miraflores.

**SUN, Han; BURTON, Henry V.; HUANG, Honglan.** Machine Learning applications for building structural design and performance assessment: State-of-the-art review. Journal of Building Engineering, 2021, vol. 33, p. 101816.

**TSONOS, Alexander-Dimitrios G.** Performance enhancement of R/C building columns and beam-column joints through shotcrete jacketing. Engineering Structures, 2010, vol. 32, no 3, p. 726-740.

**TSONOS, A. G.; STYLIANIDIS, K.** Seismic retrofit of Beam-to-Column joints with high-strength fiber jackets. European Earthquake Engineering, 2002, vol. 16, no 2, p. 56-72.

**VOLLUM, R. L.; NEWMAN, J. B.** Strut and tie models for analysis/design of external beam-column joints. Magazine of concrete research, 1999, vol. 51, no 6, p. 415-425.

**WONG, Ho Fai.** Shear strength and seismic performance of non-seismically designed reinforced concrete beam-column joints. Hong Kong University of Science and Technology (Hong Kong), 2005.

