

UNIVERSIDAD TECNOLÓGICA DE LOS ANDES

FACULTAD DE INGENIERÍA

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



Tesis:

Redes neuronales artificiales para la predicción de la resistencia a compresión del concreto de construcción a partir de sus parámetros de fabricación en la ciudad de Abancay-2024

Asesor:

PhD. Vásquez Ramírez, Abbon Alex

Autor:

Palomino Valenzuela, Janio Ignacio

Para optar el título profesional de:

Ingeniero civil

Abancay - Apurímac – Perú

2026

Acta de sustentación



UNIVERSIDAD TECNOLÓGICA DE LOS ANDES
FACULTAD DE INGENIERIA
ESCUELA PROFESIONAL DE INGENIERIA CIVIL

ACTA DE SUSTENTACIÓN DE TÍTULO PROFESIONAL

Acta N°: 032

En la ciudad de Abancay, a un (01) día del mes de julio del 2026, siendo las 11:00 am horas, se reunieron los integrantes del Jurado designado por Resolución Directoral N° 0508-2026-EPIC-FI-UTEA-SA de la Escuela Profesional de Ingeniería Civil, Facultad de Ingeniería:

Presidente :	Mag. MALDONADO MENDIVIL, Ángel
Dictaminante :	Mag. CORNEJO ROSALES, Horacio Antonio Hassan
Replicante :	Mag. ASTETE JUÁREZ, Edwin

Para evaluar la sustentación, en la modalidad de:

☒ Tesis ☐ Trabajo de suficiencia profesional

Titulada: *Redes neuronales artificiales para la predicción de la resistencia a la compresión del concreto de construcción a partir de sus parámetros de fabricación en la ciudad de Abancay – 2024.*

Desarrollado por el (los) Bachiller (es):

Br.: PALOMINO VALENZUELA, Janio Ignacio

Para optar el Título Profesional de:

Ingeniero Civil

Concluido el acto, el Jurado dictaminó que el (la) (los) mencionado(a) (s) bachiller (es) fue (ron) APROBADO(S) ☒ o DESAPROBADO(S) ☐:

Emitiéndose el calificativo final de:


Bachiller	Nota	Detalle (**)
Br. PALOMINO VALENZUELA, Janio Ignacio	17	APROBADO NOTABLE

Siendo las 12:10 horas concluyó la sesión, firmando los integrantes del Jurado.

Presidente: Mag. MALDONADO MENDIVIL, Ángel

Dictaminante: Mag. CORNEJO ROSALES, Horacio Antonio Hassan

Replicante: Mag. ASTETE JUÁREZ, Edwin



Nota: Desaprobado: 0-10; Aprobado: 11-20
(**): 0 a 10: Desaprobado, 11 a 15: Aprobado, 16 a 18: Aprobado Notable, 19 y 20: Aprobado con Distinción, Art. 18 RGGAT.

Reporte de similitud



Página 2 de 254 - Descripción general de integridad

Identificador de la entrega trn:oid::3117:606703784

7% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Coincidencias menores (menos de 8 palabras)

Fuentes principales

- 6%  Fuentes de Internet
- 3%  Publicaciones
- 0%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Metadatos

Datos del autor	
Apellidos y nombres	Palomino Valenzuela Janio Ignacio
Tipo de documento de identidad	DNI.
Numero de documento de identidad	73472954
URL ORCID	https://orcid.org/0009-0003-6380-0961
Datos del asesor	
Apellidos y nombres	Ph. D. Abbon Alex Vásquez Ramírez
Tipo de documento de identidad	DNI
Numero de documento de identidad	06532658
URL ORCID	https://orcid.org/0000-0001-7299-5367
Datos de la investigación	
Facultad	Ingeniería
Escuela Profesional	Ingeniería Civil
línea de investigación	Gestión de la Infraestructura para el desarrollo sostenible
Rango de años que se realizó la investigación	2024-2025
Fuente de financiamiento	Concurso de investigación
Porcentaje de similitud	7%
URL OCDE	https://purl.org/pe-repo/ocde/ford#2.01.01

Dedicatoria

A mi familia, por ser el pilar que me ayudo en mis momentos de duda; a mis amigos, por su compañía y apoyo constante, a mis docentes, quienes me guiaron por la senda del conocimiento. Este trabajo es también de ustedes.

Agradecimientos

Este logro no sería posible sin el continuo apoyo, amor y fe de mis padres, hermanos y familiares quienes sacrificaron tanto para que yo pudiera estudiar.

Gracias a mis hermanos Robert, Ruby, Medaly y Shanel, gracias por ser el pilar que me ayuda seguir adelante, les agradezco con el corazón.

Gracias a mis amigos Yesvier, Américo, Dennis, Cristian, Yanpier, por el apoyo mutuo, las dudas compartidas y la gran camaradería que me demostraron.

Gracias a mis docentes e ingenieros, que siempre estuvieron ahí para absorber mis dudas y apoyarme durante la elaboración de este proyecto, en especial al ingeniero Oswald, cuya guía y dedicación fue fundamental.

Y de manera especial a mi Mamita Sonia, cuya exigencia y sabiduría me ha ayudado en los momentos más difíciles de mi vida.

Resumen

La presente investigación tuvo como objetivo desarrollar un modelo de red neuronal artificial capaz de predecir la resistencia a la compresión del concreto a partir de sus parámetros de fabricación, con el propósito de fortalecer el control de calidad y reducir la dependencia exclusiva de ensayos destructivos. El estudio se desarrolló bajo un enfoque cuantitativo, de tipo aplicado y diseño experimental, considerando datos experimentales obtenidos en el Laboratorio de Suelos, Concreto y Pavimentos Lunix Ingenieros S.R.L., de Abancay, así como información procedente de tesis realizadas en la misma ciudad durante el periodo 2016-2025. La base de datos estuvo conformada por 687 registros de mezclas de concreto, integrados por 17 variables de entrada, entre ellas la relación agua/cemento, edad del espécimen, temperatura y contenido de materiales. Se implementó una red neuronal multicapa, entrenada mediante el algoritmo Adam, y su desempeño fue evaluado mediante los indicadores R^2 , MAE y RMSE. Además, los resultados fueron comparados con modelos de aprendizaje automático, como Decision Tree, Random Forest y XGBoost. El modelo propuesto alcanzó un R^2 de 0,963, un MAE de 13,94 kg/cm² y un RMSE de 17,61 kg/cm², evidenciando una alta correspondencia entre los valores reales y estimados. La edad del concreto, la relación agua/cemento y el contenido de cemento fueron las variables más influyentes. Se concluye que la red neuronal artificial desarrollada predice con alta precisión la resistencia a compresión del concreto y constituye una herramienta confiable para optimizar el diseño de mezclas y el control de calidad en laboratorios locales de Abancay.

Palabras clave: Redes neuronales artificiales, Resistencia a compresión del concreto, Predicción de propiedades del concreto, Parámetros de fabricación, Inteligencia artificial aplicada a la ingeniería civil, Diseño de mezcla y Modelos predictivos en materiales de construcción

Abstract

The present research aimed to develop an artificial neural network model capable of predicting the compressive strength of concrete based on its manufacturing parameters, with the purpose of strengthening quality control and reducing exclusive dependence on destructive testing. The study was conducted under a quantitative approach, applied in nature, and with an experimental design, considering experimental data obtained from the Soil, Concrete, and Pavement Laboratory of Lunix Ingenieros S.R.L., located in Abancay, as well as information from theses carried out in the same city during the 2016–2025 period. The database consisted of 687 concrete mix records, comprising 17 input variables, including the water-cement ratio, specimen age, temperature, and material content. A multilayer neural network was implemented, trained using the Adam algorithm, and its performance was evaluated through the R^2 , MAE, and RMSE metrics. In addition, the results were compared with machine learning models such as Decision Tree, Random Forest, and XGBoost. The proposed model achieved an R^2 of 0.963, an MAE of 13.94 kg/cm², and an RMSE of 17.61 kg/cm², demonstrating a high correspondence between actual and estimated values. Concrete age, the water-cement ratio, and cement content were the most influential variables. It is concluded that the developed artificial neural network predicts the compressive strength of concrete with high accuracy and constitutes a reliable tool for optimizing concrete mix design and quality control in local laboratories in Abancay.

Keywords: Artificial Neural Networks, Concrete Compressive Strength, Prediction of Concrete Properties, Manufacturing Parameters, Artificial Intelligence Applied to Civil Engineering, Concrete Mix Design, and Predictive Models for Construction Materials.

Índice

Portada.....	i
Acta de sustentación.....	ii
Reporte de similitud.....	iii
Metadatos.....	iv
Dedicatoria.....	v
Agradecimientos.....	vi
Resumen.....	vii
Abstract.....	viii
Índice.....	ix
Índice de tablas.....	xii
Índice de Figuras.....	xiv
Índice de Anexos.....	xvi
I. Introducción.....	17
II. Planteamiento del problema.....	19
2.1 Descripción y formulación del problema.....	19
2.2 Objetivos.....	21
2.2.1 Objetivo general.....	21
2.2.2 Objetivos específicos.....	22
2.3 Justificación e importancia.....	22

2.4	Hipótesis.....	24
2.4.1	Hipótesis General	24
2.4.2	Hipótesis Especifica	24
2.5	Variables.....	25
III.	Marco Teórico.....	28
3.1	Antecedentes	28
3.1.1	A nivel Internacional	28
3.1.2	A nivel Nacional.....	30
3.1.3	A nivel regional y local	31
3.2	Bases teóricas	32
3.2.1	Naturaleza y composición del concreto.....	32
3.2.2	Componentes principales del concreto y propiedades.....	32
3.2.3	Resistencia a compresión del concreto.....	41
3.2.4	Parámetros de fabricación que afectan a la resistencia	44
3.2.5	Redes Neuronales Artificiales	49
3.2.6	Modelo de Redes Neuronales.....	49
3.2.7	Entrenamiento de la Red	56
3.2.8	Optimizador Adam	56
3.2.9	Función de pérdida o loss Function.....	56
3.2.10	Coeficiente r de Pearson.....	57
3.3	Definición de términos	58

IV. Metodología.....	60
4.1 Tipo y Nivel de investigación	60
4.1.1 Diseño de investigación.....	61
4.2 Ámbito temporal y espacial.....	62
4.3 Población y muestra	63
4.3.1 Población	63
4.3.2 Muestra.....	63
4.4 Instrumentos	66
4.4.1 Técnicas.....	66
4.4.2 Instrumento.....	66
4.5 Procedimientos	69
4.6 Análisis de datos.....	99
4.7 Consideraciones técnicas.....	123
V. Resultados y discusión.....	125
VI. Conclusiones.....	166
VII. Recomendaciones	168
VIII. Referencias.....	170
IX. Anexos.....	175

Índice de tablas

Tabla 1 Operacionalización de variables	26
Tabla 2 Resultado de ensayos de agregado fino y grueso.....	70
Tabla 3 Resistencia a compresión requerida	70
Tabla 4 Selección de asentamiento	71
Tabla 5 Contenido de aire atrapado	71
Tabla 6 Volumen unitario de agua	72
Tabla 7 Relación agua/cemento (a/c).....	72
Tabla 8 Contenido de agregado grueso	74
Tabla 9 Diseño de mezcla en seco	76
Tabla 10 Diseño de mezcla final	78
Tabla 11 Diseño de mezcla final agregando desperdicio	78
Tabla 12 Registro de información de tesis consultadas para recolección de datos.....	81
Tabla 13 Registro de información.....	86
Tabla 14 Resultados de rotura a los 7 días	99
Tabla 15 Análisis estadístico de resultados a los 7 días.....	100
Tabla 16 Resultados de rotura a los 14 días	100
Tabla 17 Análisis estadístico de resultados a los 14 días.....	102
Tabla 18 Resultados de rotura a los 28 días	103
Tabla 19 Análisis estadístico de resultados a los 28 días.....	104
Tabla 20 Promedio de probetas de concreto según ACI 318	106
Tabla 21 Descripción variables de entrada de estudio de la RNA	107
Tabla 22 Descripción de variable de salida.....	109
Tabla 23 Formato final de base de datos para el entrenamiento de la RNA	111

Tabla 24	Análisis estadístico de toda la base de datos	112
Tabla 25	Valores de correlación de Pearson	120
Tabla 26	Variables de entrada y salida de la RNA	125
Tabla 27	Examen aleatorio de arquitecturas de prueba	126
Tabla 28	RNA con mejores resultados.....	128
Tabla 29	Arquitecturas menos complejas con mejores resultados.....	129
Tabla 30	Arquitecturas con mayores iteraciones	129
Tabla 31	Arquitectura final con aplicación de técnicas de regulación.....	129
Tabla 32	Semillas probadas en la RNA	130
Tabla 33	Arquitecturas con k-fold	131
Tabla 34	Resultados de k-fold en las arquitecturas probadas	132
Tabla 35	Resultados finales de aplicar k-fold	132
Tabla 36	Comparación final de las mejores 3 arquitecturas	138
Tabla 37	Resultado final de la RNA	139
Tabla 38	Error de predicción.....	139
Tabla 39	Verificación de no overfitting	140
Tabla 40	Métrica global de desempeño del modelo de RNA	142
Tabla 41	Métricas globales del desempeño de la RNA	143
Tabla 42	Comparación de modelos de ML con nuestra modelo de RNA.....	157
Tabla 43	Comparación con modelos de RNA.....	158

Índice de Figuras

Figura 1 Función de activación ReLU	52
Figura 2 Esquema de un perceptrón multicapa.	53
Figura 3 Red de Elman.....	55
Figura 4 Instrumento de validación para recolección de datos de tesis consultadas	67
Figura 5 Instrumento de validación para recolección de datos atmosféricos.....	68
Figura 6 Instrumento de validación de base de datos para entrenamiento.....	68
Figura 7 Pruebas de ensayos a los agregados grueso y fino	69
Figura 8 Proceso de producción y rotura de briquetas de concreto	79
Figura 9 Ejemplo de recolección de datos de las tesis citadas.	83
Figura 10 Fuente meteorológica consultada	85
Figura 11 Modelo de instrumento de recolección de datos atmosféricos	89
Figura 12 Flujograma de elaboración de la RNA	98
Figura 13 Curva de porcentaje de crecimiento del concreto de tesis consultadas	113
Figura 14 Histograma de distribución de los datos recopilados vs resistencia.....	116
Figura 15 Gráficos de dispersión de datos de Cemento, agua, agregado fino, agregado grueso y temperatura.....	117
Figura 16 Gráfico de boxplot, Cemento, agua, agregado fino, agregado grueso y temperatura.	118
Figura 17 Histograma de distribución de la resistencia a compresión del concreto	119
Figura 18 Boxplot de la resistencia a compresión del concreto.....	119
Figura 19 Matriz de correlación de Pearson elaborado en Python.....	122
Figura 20 Valores R² de arquitecturas probadas.....	128
Figura 21 Comparación de resultado obtenido por K-fold	134

Figura 22 Comparación final de coeficiente de determinación- <i>R</i>² con k-fold por cada arquitectura	135
Figura 23 Arquitectura final de RNA	136
Figura 24 Métricas de entrenamiento y validación del modelo	140
Figura 25 Grafica de crecimiento del concreto predicho por la RNA	145
Figura 26 Curva de paridad del modelo	146
Figura 27 Análisis residuales y tendencias	148
Figura 28 Boxplots de residuales por banda de resistencia.....	149
Figura 29 Boxplots de residuales por edad	151
Figura 30 Influencia de cada variable en el modelo predictivo SHAP	152
Figura 31 Evaluación de parámetros de entrada por SHAP.....	153
Figura 32 Interfase del modelo predictivo	156
Figura 33 Display de la interfase	157
Figura 34 Comparación final de modelos de ML vs RNA	160

Índice de Anexos

ANEXO 1 Matriz de consistencia.....	176
ANEXO 2 Panel fotográfico	179
ANEXO 3 Instrumentos de Validación.....	187
ANEXO 4 Análisis estadístico.....	225
ANEXO 5 Resultados de entrenamiento de la RNA	235
ANEXO 6 Estructura completa de Red Neuronal Artificial.....	246
ANEXO 7 Resultados de ensayos.....	259
ANEXO 8 Ficha técnica.....	278

I. Introducción

El concreto constituye uno de los materiales más importante dentro de la ingeniería civil moderna, teniendo un especial enfoque dentro del desarrollo de la infraestructura habitacional, vial y urbana tanto a nivel global, nacional y local. En la ciudad de Abancay, este material es indispensable para el crecimiento urbano sostenible, al ser la principal base estructural de las edificaciones, puentes y pavimentos. Su comportamiento mecánico, en especial la resistencia a la compresión nos determina la capacidad para soportar las cargas estructurales y asegurar la durabilidad de las construcciones. Esta propiedad se tiende a evaluar bajo ensayos normalizados que requieren un periodo estándar de curado de 28 días, según la normativa vigente NTP 339.034. No obstante, el procedimiento presenta una importante limitación operativa, ya que no se puede obtener resultados tempranos, disponibles para su evaluación y por consecuencia dificultar la toma de decisiones oportunas en la ejecución de obra civiles, generando sobrecostos, demoras y riesgos técnicos generalmente atribuidos a la incertidumbre sobre la calidad del concreto.

Ante esta problemática, los avances en inteligencia artificial (IA) y aprendizaje automático (Machine Learning) nos han abierto posibilidades no solo para optimizar procesos de control de calidad, sino también para un manejo adecuado del uso de materiales de construcción. Entre las principales técnicas disponibles, se encuentran las redes neuronales artificiales (RNA) que en los últimos años han mostrado una notable capacidad para modelar relaciones no lineales complejas, estas sometidas a múltiples variables de entrada y salida, emulando así el comportamiento del sistema nervioso humano. Las RNA han demostrado que pueden predecir la resistencia a la compresión del concreto a partir de sus parámetros de fabricación (relación agua/cemento, los tipos de agregados, el contenido de cemento o el uso de distintos aditivos etc.), predicciones hechas con

una alta precisión y menor tiempo de procesamiento y esto sin la necesidad de esperar los resultados experimentales en un laboratorio.

Sin embargo, la eficacia de los modelos de RNA dependen mucho de los factores geológicos y materiales que se empleen. En regiones como Apurímac, principalmente en Abancay, los materiales constructivos para la elaboración de concreto tienden a presentar propiedades diferentes a otras zonas de nuestro país. Es por eso, que la implementación de un modelo de RNA en este entorno requiere la validación empírica de datos locales, con la finalidad de garantizar la precisión de las predicciones y así simular las condiciones reales en las diferentes obras de la ciudad de Abancay. En la actualidad, no se encuentran estudios o literatura científica que aborden la aplicación de esta nueva tecnología, lo que evidencia una brecha de conocimiento.

En este contexto, la siguiente investigación propone el diseño, entramiento y la validación de un modelo predictivo apoyado en redes neuronales artificiales, empleando datos experimentales obtenidos en laboratorio y tesis de pregrado a partir de mezclas de concreto realizadas con materiales propios de la ciudad de Abancay. El principal propósito es desarrollar una herramienta capaz de predecir la resistencia a compresión del concreto a diferentes edades, considerando como variables críticas a sus parámetros de fabricación. Esta perspectiva nos permitirá optimizar los procesos constructivos, reduciendo los tiempos de espera y mejorando la toma de decisiones técnicas en los diferentes proyectos de obras civiles, contribuyendo a la mejora de la gestión tecnológica en nuestra región.

II. Planteamiento del problema

2.1 Descripción y formulación del problema

2.1.1. Realidad problemática

El concreto constituye el material de construcción más utilizado a nivel mundial esto debido a su versatilidad, resistencia y principalmente a su bajo costo. Sin embargo, la determinación de la resistencia a la compresión una propiedad esencial para garantizar la seguridad y su durabilidad estructural tradicionalmente depende de los ensayos destructivos normados que requieren 28 días de curado para obtener los resultados óptimos requeridos por normativa (ASTM C39,2020). Este procedimiento no solo genera retrasos en la verificación de la calidad del material, sino que también incrementa los costos de control y dificulta la toma de decisiones oportunas en proyectos de ingeniería civil, principalmente en obras con cronogramas ajustados.

En los últimos años, se viene incorporando técnicas de inteligencia artificial (IA) y aprendizaje automático (Machine Learning) que no solo ha permitido modelar relaciones complejas entre los componentes del concreto y sus propiedades sino también nos ha permitido optimizar procesos que generalmente eran repetitivos o mecánicos, logrando de esta manera predicciones tempranas de resistencia con alta precisión y la optimización del proceso constructivo (Qayyun et al, 2023; Silva et all, 2021). Sin embargo, la mayoría de los modelos que se encuentran disponibles se basan en bases de datos internacionales, materiales que no corresponden a la realidad de cada zona de estudio y condiciones ambientales distintas a las que se presentan en los países andinos, lo que tiende a limitar su aplicabilidad en nuestra realidad.

En el contexto peruano, los laboratorios de control de calidad aun dependen de los métodos tradicionales de ensayo y el uso de herramientas de predicción basadas en redes neuronales

artificiales (RNA) es ignorado. Estudios ya realizados en universidades de la costa norte (Olivera, 2020; Chingay,2020) nos demuestran la efectividad de estos modelos, pero sin considerar las particularidades fisicoquímicas de los agregados, la altitud o las condiciones climáticas de la altura.

En Abancay, el control de la calidad del concreto estructural depende casi en su totalidad de los ensayos destructivos realizados a los 7,14 y 28 días, de acuerdo con las normativas técnicas como la ASTM C39. Este enfoque, aunque normado, suele introducir limitaciones operativas significativas: Retrasa la retroalimentación sobre la calidad del concreto, impide la toma de decisiones oportunas en las fases iniciales de la obra y puede generar sobrecostos o deficiencias técnicas no detectadas a tiempo. En este contexto, si bien la inteligencia artificial y el aprendizaje automático han estado demostrado una eficacia en la predicción de propiedades mecánicas del concreto, su aplicación en la práctica en las regiones como Abancay es aún inexistente los modelos predictivos desarrollados internacionalmente no suelen considerar la variabilidad geológica y climática de la zona, lo que no solo restringe su aplicabilidad y confiabilidad en contextos locales. Asimismo, en el Perú, aún persiste una dependencia de los métodos empíricos tradicionales, mientras que la adopción de las redes neuronales artificiales (RNA) sigue siendo incipiente, especialmente en lugares ajenos a la capital. Es por eso que el vacío científico y tecnológico radica principalmente en modelos de predicción de resistencia a compresión del concreto validados con datos locales. Esta brecha limita la optimización del diseño de mezclas, reduce la capacidad de las respuestas ante fallas potenciales y disminuye la eficacia técnica en la ejecución de las obras. Por eso, se plantea desarrollar herramientas predictivas basadas en RNA, que aprovechen los parámetros de fabricación del concreto utilizados en la ciudad de Abancay.

2.1.2 Problema general

¿En qué medida un modelo de red neuronal artificial entrenado con parámetros locales de fabricación del concreto puede predecir con alta precisión la resistencia a compresión del concreto en laboratorios de Abancay?

2.1.3 Problemas específicos

¿Cómo influye la depuración sistemática del dataset en la calidad de los datos empleados para el entrenamiento del modelo de red neuronal artificial?

¿Qué arquitectura de red neuronal artificial permite predecir la resistencia a compresión del concreto a partir de parámetros locales de fabricación

¿Qué nivel de desempeño predictivo alcanza el modelo de red neuronal artificial mediante métricas estadísticas como R^2 , MAE y RMSE?

¿Qué diferencias de desempeño existen entre el modelo de red neuronal artificial y los modelos tradicionales de machine learning en la predicción de la resistencia a compresión del concreto?

2.2 Objetivos

2.2.1 Objetivo general

Desarrollar un modelo de red neuronal artificial capaz de predecir la resistencia a compresión del concreto a partir de sus parámetros de fabricación Abancay, Apurímac-2024.

2.2.2 Objetivos específicos

Determinar la influencia de la depuración sistemática del dataset en la calidad de los datos empleados para el entrenamiento del modelo de red neuronal artificial.

Diseñar la arquitectura de red neuronal artificial para la predicción de la resistencia a compresión del concreto a partir de parámetros locales de fabricación.

Evaluar el desempeño predictivo del modelo de red neuronal artificial mediante métricas estadísticas como R^2 , MAE y RMSE.

Comparar el desempeño predictivo del modelo de red neuronal artificial con modelos tradicionales de machine learning.

2.3 Justificación e importancia

Justificación teórica.

Esta investigación ayudara a contribuir con el fortalecimiento del conocimiento científico sobre como influyen los parámetros de fabricación del concreto en la resistencia a la compresión. Este tipo de relaciones no siempre se presentan como un comportamiento lineal como se plantea en ecuaciones, sino que, debido a la implicación de varios factores como la mano de obra, temperatura, calibración de equipos, materiales etc. Es por ello, que el uso de las redes neuronales artificiales se presenta como una alternativa ya que este tipo de modelos tienen la capacidad para identificar patrones complejos en un conjunto de datos y aproximar las relaciones no lineales entre los parámetros de entrada y la variable de salida, algo que las ecuaciones clásicas no suelen considerar.

Justificación técnica

La investigación se justifica porque se propone una herramienta de predicción capaz de apoyar en el control de calidad del concreto a través del procesamiento de datos reales de fabricación y ensayos. Este modelo está alimentado de parámetros técnicos del concreto, los cuales inciden directamente en la resistencia a compresión del concreto.

Justificación práctica y económica

Desde el punto de vista práctico esta investigación presenta una alternativa aplicable por los laboratorios, profesionales y empresas vinculadas al sector concretero, ya que una predicción anticipada de la resistencia ayuda a contribuir a que los ingenieros puedan tomar decisiones oportunas en tiempos que no requieran la espera de los 28 días, sustentada en una base de datos ya consolidados. En términos económicos, el modelo propuesto espera reducir los costos asociados a los retrocesos, desperdicio de materiales, paralizaciones, rediseños de mezcla así amortiguando el costo de futuros problemas que esto conlleve en la obra.

Justificación social y ambiental

Desde el punto de vista social, esta investigación se justifica porque el concreto es el principal material usado en las obras de construcción. Una mejor predicción de su resistencia contribuye indirectamente a la prevención de problemas en obra, a la seguridad, a la durabilidad, y confiabilidad en las estructuras construidas en la ciudad de Abancay. Desde un enfoque ambiental, el estudio busca contribuir como una herramienta que nos permita analizar el comportamiento de la resistencia sin la necesidad de recurrir al excesivo uso de materiales de obra y el costo que acarrea la elaboración y destrucción de cilindros de concreto, así apoyando a la mitigación del impacto ambiental producido por el concreto.

Importancia

La importancia de la presente investigación se enfoca en la elaboración de una herramienta predictiva de concreto que resulta altamente relevante en nuestro contexto local ya que la verificación de la resistencia a compresión del concreto radica principalmente en los ensayos destructivos a 28 días, lo que tiende a retrasar la toma de decisiones en obra durante el periodo de espera. Bajo esta problemática el estudio es importante porque nos permite complementar los métodos tradicionales de control de calidad mediante modelos predictivos capaces de alinear relaciones complejas algo que los modelos tradicionales no toman en consideración.

2.4 Hipótesis

2.4.1 Hipótesis General

HG: El modelo de red neuronal artificial entrenado con parámetros locales de fabricación del concreto alcanza un desempeño predictivo alto en la estimación de la resistencia a compresión del concreto en laboratorios de Abancay, Apurímac, 2024.

2.4.2 Hipótesis Especifica

HE1: La depuración sistemática del dataset mejora la calidad de los datos empleados en el entrenamiento del modelo de red neuronal artificial.

HE2: La arquitectura de red neuronal artificial diseñada permite modelar la relación no lineal entre los parámetros de fabricación y la resistencia a compresión del concreto.

HE3: El modelo de red neuronal artificial alcanza un desempeño predictivo alto, evidenciado por un $R^2 \geq 0.90$ y valores reducidos de MAE y RMSE.

HE4: El modelo de red neuronal artificial presenta mejor desempeño predictivo que los modelos tradicionales de machine learning.

2.5 Variables

Variable 1:

Parámetros de fabricación del concreto.

Variable 2:

Propiedades mecánicas del concreto.

Tabla 1*Operacionalización de variables*

Variables	Definición Conceptual	Definición Operacional	Dimensión	Indicador	Instrumentos	Escala de Medición
Independiente: Parámetros de fabricación del concreto	Parámetros de fabricación: Según Otazzino Pasino (2016), los parámetros de fabricación del concreto son las variables que determinan las propiedades y calidad del concreto fresco y endurecido. Estos incluyen la relación agua/cemento, la dosificación de los materiales (cemento, agua, agregados y aditivos), el tipo y granulometría de los agregados y el curado. Su correcta mezcla y control aseguran que el concreto satisfaga con las condiciones de resistencia, durabilidad y trabajabilidad indicados para su uso estructural.	Se medirán mediante una ficha de registro de datos de laboratorio y base de datos técnica, en la cual se consignarán los valores cuantitativos de dosificación, propiedades de agregados, edad del concreto y condiciones de curado. Estos datos funcionarán como variables de entrada para el modelo de red neuronal artificial.	-Diseño de mezcla	-Cantidad de cemento	-Ficha de registro	-De razón
				- Cantidad de agua	-Ficha de registro	-De razón
				-Cantidad de agregado fino	-Ficha de registro	-De razón
				-Cantidad de agregado grueso	-Ficha de registro	-De razón
				-Cantidad de aditivos	-Ficha de registro	-De razón
			--Propiedades físicas de los materiales	-Contenido de humedad	-Ficha de registro	-De razón
				-Porcentaje de absorción	-Ficha de registro	-De razón
				-Módulo de fineza	-Ficha de registro	-De razón
				-Contenido de humedad	-Ficha de registro	-De razón
				-Tamaño máximo nominal	-Ficha de registro	-De razón
			-Condiciones de curado	-Edad de concreto	- Ficha de registro	-De razón
				-Temperatura	- Ficha de registro	-De razón

		- Desempeño mecánico	- Resistencia a compresión	-Máquina	- De razón
Dependiente:	La resistencia a la compresión	Se determinará a partir del	del concreto	simple (kg/cm²)	universal de
	forma parte de las propiedades mecánicas del	valor de resistencia obtenido mediante	endurecido	compresión	
Resistencia a la	concreto y expresa su capacidad para resistir	ensayo de compresión de probetas de			
compresión del	cargas de compresión; constituye una	concreto, registrado en kg/cm². En el			-Ficha de registro
concreto	propiedad relevante para evaluar la calidad	modelo de red neuronal artificial, esta			
	del concreto y su aptitud estructural (Neville,	variable corresponde a la variable			
	1995).	objetivo o variable de salida.			

Nota. Matriz de operalización de variables

III. Marco Teórico

3.1 Antecedentes

3.1.1 A nivel Internacional

Wassim (2020) examinó modelos de Aprendizaje Máquina (ML) para predecir las propiedades mecánicas del concreto, incluyendo redes neuronales artificiales (ANN), máquina de vectores soporte (SVM), árboles de decisión, y algoritmos evolutivos. Los modelos demostraron obtener resultados más precisos comparados con los modelos estadísticos tradicionales de regresión lineal y no lineal, que pueden proporcionar resultados incorrectos cuando la conexión entre las propiedades mecánicas y los componentes de la compuesto y condiciones de curado son complejas. Dado que todos los enfoques de ML analizados anteriormente presentan diversas ventajas e inconvenientes, la selección del modelo más adecuado se basa en diferentes criterios. La naturaleza de la relación entre los ingredientes de la mezcla de hormigón y su resistencia mecánica es un aspecto crucial que afecta en la elección del modelo. El autor concluye que, si esta relación es altamente no lineal y se ve afectada por varias características, el empleo de modelos como ANN y SVM sería una buena elección debido a su gran capacidad para resolver problemas en entornos no lineales con un error menor. Para obtener resultados más precisos y mejorar el proceso, resulta eficaz optimizar estos modelos con algoritmos metaheurísticos. Sin embargo, cuando se requiere transparencia en el modelo, pueden emplearse árboles de decisión y algoritmos evolutivos porque pueden generar fórmulas matemáticas explícitas que describen mejor la relación física entre entradas y salidas. Aun así, la precisión de ambos modelos es inferior a la de los modelos híbridos y autónomos de RNA y SVM.

Qayyum et al. (2023) Desarrollaron un modelo de red neuronal artificial utilizando el procedimiento de retropropagación Levenberg-Marquardt para prever la resistencia a la compresión del concreto normal y concreto de alta resistencia, la confiabilidad de este modelo fue evaluada a través de un extenso repertorio de datos que comprende la cantidad de 1637 pruebas. Para esta investigación se utilizaron 8 variables de entrada, que comprendían desde el contenido del cemento, contenido de agua, agregados, aditivos, edad del concreto etc. y un total de 33 capas ocultas que fueron la cantidad óptima que se obtuvo a través de los análisis, este a su vez fue validado a través del k-fold cross-validation and statistical measures y otros modelos de redes neuronales artificiales (ANN) existentes. Las soluciones obtenidas muestran que el modelo de red neuronal artificial (ANN) predijo eficientemente la resistencia a la compresión del concreto normal y concreto de alta resistencia, a través de los datos de entrada indicados, el modelo fue preciso en el análisis de una larga base de datos comparados con la literatura existente, el estudio de los resultados evidenció que la cantidad de cemento y los aditivos son los dos factores que tienen un mayor impacto en la resistencia a la compresión del concreto.

Silva et al. (2021) investigaron el potencial de aplicar las redes neuronales artificiales con el objetivo de valorar la resistencia a la compresión del concreto (f'_c) enfocado en parámetros relevantes de los elementos que lo componen, tales como (el ratio de agua-cemento, el ratio de agregado-cemento, edad de testeo, y el porcentaje de cemento). Se tomó una cantidad de 162 probetas de concreto y 27 elementos prismáticos con secciones medidas, elaborados con 9 diferentes diseños de mezcla. Estos fueron sometidos a un ensayo de pulso ultrasónico a una frecuencia de 54kHz, a su vez se elaboró diversos modelos de redes neuronales artificiales con distintas configuraciones las cuales fueron probadas y comprobadas para identificar el mejor modelo de ANN. Donde se llegó a la conclusión que usando el modelo de redes neuronales

artificiales se pudo obtener resultados con menos del 5% de error y que usando este modelo de ANN fue posible tener el acceso a cada variable de entrada para corroborar el f'_c del concreto.

3.1.2 A nivel Nacional

Olivera (2020) desarrollo un tipo de Redes Neuronales Artificiales (ANN) basado en el perceptrón multicapa que facilitó la predicción de la resistencia al esfuerzo de compresión del concreto. El autor recolecto información de la rotura de 946 probetas que fueron tomadas como base de datos. La preparación de las redes neuronales artificiales se realizó con el proceso MLPRegressor a través del software de programación Python, donde simulo el perceptrón multicapa permitiéndole a la red la capacidad de aprender. Usando esta metodología se pudo conjeturar el desarrollo de la resistencia de un concreto de baja, media, y alta, en cualquier edad de vida y condiciones ambientales adecuadas.

Chingay (2020) diseño modelos de redes neuronales artificiales con el fin de calcular la resistencia a la compresión del concreto, se realizó a través de la conformación de datos (variables de entrada) constituida por el diseño de mezcla, propiedades como la proporción de insumos, propiedades físicas de los materiales etc, y la resistencia a la compresión de las briquetas de concreto de acuerdo con los parámetros establecidos en la normativa vigente NTP 339.034, los datos utilizados para la prueba de la investigación, fueron tomados del repositorio de las universidades del Señor de Sipán y la Universidad Cesar Vallejo. Estos datos fueron usados para entrenar y validar los modelos a utilizar, modelos que fueron programados empleando el algoritmo Levenberg Marquardt y la metodología llamada propagación hacia atrás, los modelos planteados cuentan con 20 variables de independientes y una variable dependiente del cual se pudo obtener la red neuronal artificial con un R^2 superior. Una vez obtenida el modelo de red neuronal artificial se comenzó a elaborar las 48 briquetas de concreto, los cuales fueron sometidos al ensayo de

compresión, y su posterior evaluación con los productos obtenidos del modelo de red neuronal artificial planteado, llegando a la conclusión de que el uso de redes neuronales artificiales es un enfoque efectivo para anticipar la resistencia a la compresión del concreto por la similitud en los resultados alcanzados en los ensayos.

Villegas (2019) Realizo la comprobación del ensayo de esclerometría y un prototipo de redes neuronales artificiales-artificial neural network (ANN) con el fin de predecir la resistencia a la compresión del concreto (f'_c), las variables utilizadas para su investigación fueron la relación directa entre el agua-cemento, tiempo del concreto, condiciones ambientales y características de los agregados. En base a estas variables de estrada y las muestras diseñadas en base a la normativa vigente, se procedió a probar el prototipo de red neuronal artificial, teniendo como resultado una predicción con bajo rango de error y que estas condiciones influyen significativamente en la obtención de resultados del f'_c .

3.1.3 A nivel regional y local

Dentro del ámbito regional y local, hasta ahora no se han llevado a cabo investigaciones directamente relacionados a modelos predictivos de resistencia a la compresión del concreto usando redes neuronales artificiales que abordamos en este proyecto. Dada la novedad de este tema de investigación, este proyecto adquiere relevancia al proponerse como pionero en el área, generando además futuras investigaciones relacionadas con este campo tan innovador y de gran aporte científico. De este modo, se contribuirá al desarrollo científico de la región.

3.2 Bases teóricas

3.2.1 Naturaleza y composición del concreto

De acuerdo con Mehta & Monteiro (2024) el concreto es un material que está compuesto heterogéneamente por una mezcla de cemento hidráulico, agregados tanto fino - como grueso y agua, se suele optar en ocasiones con aditivos químicos o adiciones minerales. Después del mezclado y su fraguado, la reacción química que suele ocurrir entre el cemento y el agua es conocida como hidratación, se produce una mezcla cohesiva que une a los agregados y le confiere la resistencia y durabilidad al material. Desde el punto de vista de la ingeniería, el concreto se suele definir por sus propiedades funcionales, como la resistencia a la compresión, trabajabilidad, durabilidad y módulo de la elasticidad, que suelen depender de la composición, así como de las condiciones de su fabricación y curado.

3.2.2 Componentes principales del concreto y propiedades

3.2.1.1. *Cemento*

El cemento portland suele ser el aglutinante más usado en los concretos convencionales. Si lo evaluamos químicamente, el Clinker del cemento está conformado principalmente de silicatos y aluminatos de calcio, cuya proporción y finura suelen determinar la cinética de la hidratación, la liberación del calor y la ganancia temprana o tardía de la resistencia (Mehta & Monteiro, 2014). En la actualidad existen varias tipologías comerciales (Tipos I-V), según especificaciones de la ASTM estas varían en contenido de fases y aditivos, para controlar el calor de hidratación, su resistencia temprana y la resistencia a los sulfatos, entre otros aspectos, sus características físicas, químicas y mecánicas son los requisitos normativos que aseguran su desempeño.

3.2.1.2. *Agregado fino*

El agregado fino, este compuesto en su mayoría por arena natural o triturada, este actúa como un elemento de relleno entre las partículas del agregado grueso y contribuye a la cohesión de la mezcla. También regula la trabajabilidad y la estabilidad volumétrica del concreto, ya que debido a su gradación y su textura superficial se determina la demanda de agua y la densidad del mismo sistema (Mehta & Monteiro, 2014) según la ASTM C33/C33M (2018) y la NTP 400.037 (SENCICO, 2019), se define que el agregado fino debe pasar completamente por el tamiz N.º 4 (4.75mm) y este debe contener una cantidad controlada de material menor al tamiz N.º 200 para controlar la excesiva plasticidad.

Propiedades principales del agregado fino:

a) Peso unitario

Como afirma Mindess et al (2021) el peso unitario del agregado fino, que se determina mediante la ASTM C29/C29M, representa la masa por su unidad de volumen del material compactado. Los valores usuales suelen variar entre 1200 y 1750 kg/m^3 , lo que indica una densidad representativa del material. Tener un peso unitario alto permitirá una mejor distribución de la granulometría y menor porcentaje de los vacíos, estas condiciones favorecen a la resistencia a compresión y la estabilidad dimensional del concreto.

Es aspectos prácticos, esta propiedad nos permite estimar la dosificación volumétrica y así controlar la consistencia del concreto fresco, especialmente si se emplean arenas de distinta procedencia. Según Neville (2011), la variación del peso unitario en la arena de un mismo lote tiende a afectar la uniformidad del concreto, produciendo diferencias en su asentamiento, exudación o segregación, por lo que es recomendable realizar los controles rutinarios de esta variable en la planta o el laboratorio.

b) Módulo de fineza

Como indica Mehta & Monteiro (2014) nos indican que el módulo de fineza representa el grado de finura o la distribución granulométrica del agregado, el cual es calculado como la suma de los porcentajes retenidos acumulados en tamices normalizados (3/8'', N.º4, N.º8, N.º16, N.º30, N.º50 y N.º 100), dividida entre 100, establecido por la ASTM C136/C136M (2018). Tener un módulo de fineza entre 2.3 y 3.1 se considera adecuado para los concretos estructurales, esto debido a que las arenas más finas incrementan la demanda de agua y cemento, mientras que arenas más gruesas suelen reducir la cohesión de la mezcla.

Además, teniendo la selección apropiada del módulo de fineza asegura la compatibilidad entre el agregado fino y grueso, de esta forma se evita la segregación o vacíos excesivos. Según Mindess et al. (2021), si se mantiene el módulo de fineza constante dentro de la plata de producción es un indicador de un control de calidad adecuado. Un cambio de ± 0.2 en el módulo, puede afectar el slump en de 20mm, afectado la relación de agua/cemento efectivo y por lo tanto la resistencia final del concreto.

c) Tamaño máximo nominal

De acuerdo con la ASTM C136 donde el tamaño máximo nominal del agregado fino se define como el menos tamiz por el que pasa el 100% del material, en las arenas, comúnmente corresponde al tamiz N.º4 (4.75mm). Este parámetro asegura una mezcla homogénea, un mejor compacidad y resistencia a la segregación durante el proceso de colocación del concreto.

Como señala Neville (2011), nos indica que el exceso de las partículas mayores a 5mm puede disminuir la cohesión, mientras que un déficit en los granos gruesos aumenta la exudación y retracción plástica.

d) Absorción

Según Mehta & Monteiro (2014) quienes señalan que la absorción representa la cantidad de agua que puede retener un agregado en sus poros cuando alcanza el estado de saturación superficial seco. Este se determina a según la ASTM C128 y tiene a variar entre 0.5% y 3% para arenas naturales. Si se obtiene una absorción elevada, esto reflejara una mayor porosidad interna y puede afectar la relación agua/cemento efectivo, afectando la resistencia y durabilidad del concreto.

Asimismo, Neville (2011) nos señala que la absorción no depende solo del tipo de roca, sino también de los métodos de procesamiento. Las arenas trituradas tienden a tener una mejor absorción que las naturales por su angularidad y sus microfisuras.

e) Humedad

Según Neville (2011) quien indica que la humedad superficial del agregado fino se evalúa con el fin de ajustar la cantidad de agua que se agregara en el diseño de mezcla, mostrándose como el porcentaje de la masa seca (ASTM C566). Dependiendo de su condición, el agregado se puede clasificarse entre seco, seco al aire y húmedo. Un manejo inadecuado de su control puede provocar desviaciones importantes en su trabajabilidad o en la resistencia misma del concreto a compresión.

El control de la humedad es principalmente relevante en lugares con climas variables, donde las arenas pueden absorber o liberar agua rápidamente.

f) Peso específico

De acuerdo con Mindess et al (2021) quien nos indica que el peso específico del agregado fino, medido con la ASTM C128 expresa la relación entre el peso del material seco y su volumen sólido, incluyendo sus poros impermeables. Los valores se encuentran entre los 2.55 y 2.7 g/ cm³,

y esto suele variar dependiendo de la mineralogía de la roca. Esta propiedad se usa para la conversión de proporciones volumétricas en el diseño de la mezcla y para la estimación de la resistencia potencial del concreto.

Desde el punto de vista de Mehta y Monteiro (2014) un valor de densidad bajo nos puede indicar la presencia de impurezas, arcillas o materiales ligeros que pueden reducir la cohesión. Además, que el peso específico del agregado fino suele guardar una correlación con la resistencia mecánica de la mezcla.

3.2.1.3. Agregado grueso

El agregado grueso suministra al concreto su resistencia estructural, rigidez y la estabilidad volumétrica. Está conformado principalmente por partículas de tamaño superior a los 4.75 mm y hasta un máximo de los 37.5, esto de acuerdo con la ASTM C33/C33M (2018) o la NTP 400.037 (SENCICO, 2019). Las propiedades físicas actúan directamente en la adherencia del mortero, en su durabilidad y su resistencia mecánica.

Propiedades principales del agregado grueso:

a) Peso unitario

Como señala la ASTM C29/C29M donde indica que el peso unitario del agregado grueso representa la masa por unidad de volumen del material compactado. Valores comúnmente entre 1200 y 1700 kg/ m³, dependiendo de su forma, textura y compactación de las partículas. Según Mindess et al, (2021) nos indican que un mayor peso unitario implica una mejor gradación y menor cantidad de los vacíos, lo que puede traducirse en concretos más densos y resistentes.

Además, Neville (2011), el control del peso unitario se indispensable en plantas dosificadoras, pues sus variaciones superiores al 5% pueden alterar la relación volumétrica y modificar su trabajabilidad.

b) Módulo de fineza

Según Mehta & Monteiro (2014) definen al módulo de fineza en agregados gruesos como indicador de gradación. Valores que se encuentran entre 6.0 y 7.5 reflejan gravas bien graduadas que facilitan el empaque y reducen la cantidad de la pasta requerida.

Mientras Mindess et al (2021) señala que un alto módulo de fineza sugiere que las partículas son demasiado grandes y huecos interparticulares amplios, lo que disminuye la cohesión. Por otro lado, valores bajos indican predominio de las fracciones finas que pueden aumentar la demanda de agua, también señala que mantener la gradación continua de agregados gruesos optimiza la trabajabilidad.

c) Tamaño máximo nominal

El tamaño máximo nominal se define como el tamiz inmediatamente superior por el cual pase el 95% del material. Su elección se enfoca principalmente del tipo de elemento estructural y del espaciamiento de las armaduras, conforma a la normativa vigente. El tamaño del agregado influye en la demanda de agua y en su resistencia final: agregados mayores tienden a reducir la superficie específica y por lo tanto el contenido de mezcla necesario, mientras que el tamaño máximo nominal sea excesivo puede dificultar el bombeo y generar segregación (Neville,2011).

d) Absorción

Como indica Mehta & Monteiro (2014) que el porcentaje de absorción del agregado grueso, determinado bajo la normativa ASTM C127 mide la cantidad de agua retenida en los poros tras 24

horas de inmersión y suele situarse entre el 0.3% y 2.0%. Valores altos indican que son materiales más porosos, susceptibles a deterioro por ciclos de congelamiento o por ataques de sales.

Mientras que Neville (2014) nos indica que la diferencia entre 1% en la absorción puede alterar la relación de agua/cemento en 0.02 unidades, de esta manera afectando a la resistencia a compresión. Es por esto por lo que los laboratorios deben registrar la absorción promedio de cada fuente de agregado y ajustar el agua a la mezcla de manera continua.

e) Humedad

El contenido de humedad del agregado grueso se controló bajo métodos de secado rápido o usando horno, conforme a lo establecido en la ASTM C566. Este factor repercute en la masa unitaria y en su relación agua/cemento efectivo. En climas templados la humedad puede fluctuar considerablemente durante la ejecución, modificando la uniformidad de la mezcla (MVCS, 2020).

3.2.1.4. Agua

Según Mehta & Monteiro (2014) quienes indican que el agua cumple con una doble función, participar en la reacción química de hidratación y también proporcionar trabajabilidad en el concreto fresco. Además, la cantidad de agua que se utiliza tiene que ser suficiente para lograr una hidratación completa del cemento, pero sin exceder los límites que adicionan la porosidad del material. Una relación agua/cemento (a/c) óptima es fundamental para conseguir una estructura densa y resistente.

Mientras que Neville & Brooks (2010) destacan que el exceso de agua en el concreto tiende a producir capilaridad interconectadas, reduciendo su resistencia a compresión y aumentando la permeabilidad, lo que tiende a producir una aceleración en la corrosión del acero de refuerzo. La normativa vigente como la ASTM C1602/C1602M-18 nos indica que los requisitos de calidad del

agua para el mezclado deben ser libres de aceites, ácidos y sustancias orgánicas que puedan afectar la hidratación.

3.2.1.5. Aditivos

De acuerdo con Neville (2011) los aditivos químicos permiten modificar las propiedades específicas del concreto fresco o endurecido, así como su trabajabilidad, el tiempo de su fraguado o la resistencia. La norma ASTM C494/C494M-19 clasifica a los aditivos en seis tipos principales: Superplastificantes, retardantes, acelerantes, reductores de agua, plastificantes y combinados. Además, sostiene que los aditivos son las herramientas esenciales para una optimización en el desempeño del concreto, esto enfocado en condiciones ambientales extremas o en situaciones donde se requiera un control preciso del tiempo de fraguado.

Mientras Thomas (2013) nos indica que la función de los aditivos minerales (cenizas volantes, humo de sílice, escorias o puzolanas naturales) como materiales suplementarios al cemento. Estos mejoran la microestructura del concreto, además de reducir la permeabilidad y mejorar su durabilidad frente a los agentes agresivos. También actúan como captadores de hidróxido de calcio, así incrementado la proporción del gel C-S-H , lo cual favorece la resistencia a largo plazo del concreto.

3.2.1.6. Edad del concreto

De acuerdo con Neville (2011) la edad del concreto es un factor determinante en su evolución de la resistencia a compresión. El concreto continúa ganado resistencia a medida que el tiempo avanza, esto debido a la hidratación progresiva del cemento, su resistencia aumenta rápidamente durante los primeros 7 días, alcanzando el 70% de su valor final y continuando con un ritmo más lento hasta los 28 días, edad convencional de su evaluación estructural.

Según Mindess et al (2016) nos indica que la velocidad de ganancia de la resistencia depende del tipo de cemento, su relación a/c y las condiciones ambientales de la zona. En lugares con climas cálidos, el proceso de hidratación se acelera, lo cual puede verse afectado por la rápida evaporación del agua, lo que justifica la importancia de un curado controlado para así evitar fisuración por contracción plástica.

3.2.1.7. *Slump*

La consistencia del concreto fresco se evalúa bajo el ensayo de asentamiento o también conocido como slump, el cual esta descrito en la ASTM C143/C143M-15. Este ensayo nos determina la capacidad de la mezcla de concreto para fluir y llenar los encofrados sin segregarse, Según Kosmatka et al. (2016) quien nos indica que la consistencia adecuada nos garantiza una compactación eficiente y una distribución homogénea de los componentes, factores esenciales para conseguir una estructura sin vacíos ni discontinuidades.

Mientras que Mehta y Monteiro (2014) nos indican que el slump ideal suele variar según el tipo del elemento estructural: Mezclas más secas son preferibles para pavimentos y losas, mezclas más fluidas se utilizan para estructuras densamente armadas. Pero un exceso en la fluidez puede inducir a la segregación y disminuir la resistencia.

3.2.1.8. *Temperatura y humedad relativa*

La temperatura y humedad relativa son factores ambientales que afectan directamente a la hidratación del cemento. Según Neville & Brooks (2010) quienes explican que las temperaturas elevadas aceleran la hidratación inicial, aumentando la resistencia temprana, pero tienden a generar microfisuras internas y reducen la resistencia a largo plazo. De la misma manera, las temperaturas bajas ralentizan el fraguado y pueden detener la hidratación si se aproximan al punto de congelación.

El ACI 305R-20 nos recomienda tener condiciones controladas de temperatura y de humedad durante las primeras 48 horas de curado, así evitar las pérdidas prematuras de agua. Según Mehta & Monteiro (2014) quienes señalan que la humedad relativa superior al 90% suele favorecer una hidratación completa, por otro lado, valores inferiores generan secado superficial, fisuras y retracción plástica. En algunas regiones donde las variaciones térmicas diurnas son altas, es indispensable la aplicación de técnicas para el curado húmedo o el uso de membranas sellantes para conservar la humedad del concreto.

3.2.3 Resistencia a compresión del concreto

3.2.2.1. Concepto e importancia estructural

La resistencia a compresión del concreto es la propiedad mecánica más importante, ya que indica su capacidad para soportar las cargas axiales antes de fallar. De acuerdo con Neville (2011) quien nos indica que la resistencia se define como la máxima carga a compresión que los especímenes cilíndricos de concreto pueden soportar antes de fracturarse, dividida entre el área de contacto de su sección transversal. Esta propiedad constituye el principal parámetro para el diseño estructural, al ser el principal valor para la clasificación de los concretos según las normas técnicas, y este valor depende de múltiples factores de fabricación, curado y su composición.

Mientras que Kosmatka, Kerkhoff y Panarese (2016) quienes indican que la resistencia compresión del concreto además de reflejar la calidad de los materiales, también nos muestra la eficiencia del proceso constructivo. Una mezcla adecuadamente proporcionada y curada nos permitirá alcanzar un desempeño estructural superior, mientras que los errores en el control de los materiales o procedimientos de compactación suelen generar reducciones significativas de resistencia. En la práctica profesional, esta propiedad es indispensable para asegurar la durabilidad

y protección de las estructuras frente a las cargas estáticas o dinámicas, así como hacer frente a las condiciones ambientales adversas.

“La resistencia a compresión es el indicador más representativo del comportamiento global del concreto y constituye el parámetro de aceptación más común en la ingeniería estructural moderna” (Neville & Brooks, 2010, p. 124).

3.2.2.2. Mecanismos de falla y comportamiento bajo carga

El concreto es un material cuasi-fragil, y su comportamiento sometido a cargas de compresión se caracteriza por el incremento lineal inicial de esfuerzo y deformación hasta conseguir un punto máximo, seguido además de una fractura abrupta. Como lo infica Mindess, Young y Darwin (2016), la falla que tiende a ocurrir es debido a la propagación de una microfisura en el concreto y en la zona de transición en la misma interfase, donde se encuentran las tensiones debido a las diferencias de rigideces entre los agregados y su mortero. Estas microfisuras suelen desarrollar y unirse hasta formar una fractura macroscópica que terminara con el colapso del espécimen.

Mientras que Mehta y Monteiro (2014) nos indican que el concreto absorbe la energía elástica hasta cierto punto, mientras ocurre un fenómeno de daño progresivo y la pérdida de rigidez. La resistencia final estará influenciada por la distribución de los vacíos, la adherencia entre las fases y la microestructura del mortero. Es por eso que la forma del espécimen y su velocidad de aplicación de la carga también afectan al resultado del ensayo de compresión, siendo el más común la relación altura -diámetro de los cilindros de concreto los más empleados en las normas internacionales.

“La falla en compresión no es instantánea ni uniforme, sino el resultado de un proceso de acumulación de microfisuras en la pasta y la interfaz con los agregados, lo que define la naturaleza cuasi-frágil del material” (Mindess et al., 2016, p. 189).

3.2.2.3. Factores determinantes de la resistencia

La resistencia a la compresión depende de la combinación de diversos factores intrínsecos y extrínsecos. Los más relevantes son la relación agua/cemento, la calidad de los materiales, el grado de compactación, el tipo de curado, la temperatura y la edad del concreto (Neville, 2011). La ley de Abrams se establece que la resistencia es inversamente proporcional a la relación a/c, lo que nos indica que las mezclas más densas y con menor contenido de agua tienden a producir concretos más resistentes.

De acuerdo con Mehta y Monteiro (2014) quienes indican que la relación a/c, influye en la porosidad, su tamaño máximo nominal del agregado y la energía del mezclado. Además, una compactación deficiente o segregación durante el colado crean zonas con vacíos, así disminuyendo su área efectiva de carga. Mientras que el curado en condiciones inadecuadas puede reducir la resistencia más del 30%. Asimismo, el tipo de cemento y la adición de los materiales puzolánicos tienden a modificar la velocidad de hidratación y su respectivo desarrollo microestructural del concreto.

“Entre todos los factores que afectan la resistencia, la relación agua/cemento sigue siendo el más influyente, y pequeñas variaciones pueden causar grandes diferencias en el comportamiento final del material” (Kosmatka et al., 2016, p. 241).

3.2.2.4. Evolución temporal de la resistencia

La resistencia del concreto evoluciona en el tiempo a medida que su hidratación al cemento avanza. Durante las primeras horas, el fraguado genera una estructura inicial, y durante los

primeros 7 días ocurre un considerable incremento de la resistencia, alcanzando entre el 60% y el 70% del valor final. Según Thomas (2013), quien asegura que el crecimiento depende de la temperatura, la humedad y el tipo de cemento que se emplea. La curva de maduración representa gráficamente esta evolución, mostrando la ganancia de la resistencia es rápida durante los primeros días y luego comienza a desacelerar gradualmente hasta estabilizarse alrededor de los 28 días, edad estándar para el control de su calidad.

Mientras que Mindes et al. (2016) nos indican que la hidratación continua incluso después de los característicos 28 días, pero ya con un ritmo mucho más lento. En lugares con humedad adecuada, el concreto puede incrementar su resistencia hasta un 20% adicional entre los 28 y 90 días. Inclusive modelos matemáticos modernos, como el de Carino (1991), que permite predecir la resistencia en función de la madurez del concreto, mezclando el tiempo y la temperatura es una sola variable. Este enfoque es indispensable para la optimización del curado en campo, especialmente en zonas variables.

“La madurez del concreto refleja el grado de avance de las reacciones de hidratación y constituye un indicador confiable de la resistencia potencial alcanzable bajo condiciones dadas de curado y temperatura” (Thomas, 2013, p. 278).

3.2.4 Parámetros de fabricación que afectan a la resistencia

3.2.3.1. Relación agua/cemento y su impacto en la porosidad

La relación agua/cemento (a/c) es el factor más determinante en la resistencia a compresión del concreto. Según Abrams (1918) quien formulo empíricamente que la resistencia es inversamente proporcional a su contenido de agua en la mezcla, lo que dio como resultado la conocida ley de Abrams, la cual estableció que al disminuir la relación a/c, la resistencia

característica del concreto aumenta exponencialmente hasta cierto límite. Neville (2011) nos indica que este resultado se debe a que una menor cantidad de agua reduce la porosidad capilar del material, así generando una estructura continua y más densa.

Por su parte, Mehta y Monteiro (2014) indican que la relación a/c se encarga de manejar el volumen de poro interconectado en el mortero, lo cual afecta directamente a la durabilidad y a su permeabilidad del concreto. Una mezcla con exceso de agua terminara presentando microfisuras y alta absorción, por otro lado, mezclas más secas pueden dificultar la compactación y provocar vacíos. Ante ello, se debe tomar en cuenta una relación a/c optima dependiendo del tipo de cemento, agregado y el método de curado en uso.

“Para un cemento dado y condiciones constantes de curado, la resistencia del concreto varía fundamentalmente con la relación agua-cemento; cuanto menor sea esta relación, mayor será la resistencia obtenida” (Neville, 2011, p. 322).

3.2.3.2. Tipo y cantidad de cemento

Como afirma Kosmatka, Kerkhoff y Panarese (2016) quienes afirman que el tipo de cemento y su proporción en la mezcla influyen considerablemente en su resistencia y respectivamente en el desarrollo de la microestructura del concreto. También indican que los cementos con mayor concentración de silicato tricálcico (C_3S) suelen desarrollar resistencias iniciales elevadas, por otro lado, los que contienen más silicato dicálcico (C_2S) ayudan a la resistencia a edades avanzadas. La cantidad de cemento es indispensable para determinar el volumen de la pasta disponible para unir los agregados, pero un exceso significativo puede generar la contracción y fisuración térmica.

La finura de los cementos también influye directamente en la velocidad de hidratación. Cementos más finos tienden a reaccionar más rápidamente, acelerando su fraguado y el

endurecimiento, pero esto también genera un mayor control sobre la temperatura. En uso estructurales, la selección del tipo de cemento debe adecuarse a las condiciones ambientales, teniendo mayor énfasis en zonas cálidas o en zona que se encuentran expuestas a sulfatos (Mindess, Young y Darwin, 2016).

“El incremento del contenido de cemento mejora la resistencia inicial, pero no garantiza una durabilidad superior; lo esencial es alcanzar una microestructura compacta y estable con una adecuada relación agua-cemento” (Kosmatka et al., 2016, p. 187).

3.2.3.3. Caracterización de los agregados

Los agregados locales desempeñan un papel esencial en la resistencia final del concreto, ya que son indispensable en el esqueleto estructural del concreto. Las propiedades físicas y químicas de estos agregados tienden a determinar la adherencia con la pasta de cemento y su distribución de las tensiones internas (Neville, 2011).

Citando a Mehta y Monteiro (2014) donde añaden que los agregados gruesos que cuentan con superficies rugosas y angulares tienen una mejor adherencia y resistencia mecánica, aunque como consecuencia pueden reducir la trabajabilidad de la mezcla. Mientras que agregados más redondeados, típicos de depósitos fluviales, facilitan la colocación de la mezcla, pero a cambio disminuyen la fricción interna. También debe tomarse en cuenta la presencia de materiales deleznales, como las arcillas o limos, que afectan la resistencia y tienden a provocar reacción como la conocida reacción álcali-silice.

“La calidad de los agregados no puede compensarse con un alto contenido de cemento; su naturaleza mineralógica y su pureza determinan la durabilidad y la integridad del concreto” (Mehta & Monteiro, 2014, p. 215).

3.2.3.4. Aditivos químicos y minerales

Para la elaboración del concreto también se suelen usar aditivos químicos y minerales, es una estrategia indispensable para modificar y controlar las propiedades del concreto fresco y endurecido. De acuerdo con la ASTM C494-19, los aditivos químicos suelen actuar como reductores de agua, retardantes, acelerantes o plastificantes, estos se encargan de ajustar la trabajabilidad y su velocidad de fraguado. Según Neville (2011) indica que los productos químicos nos permiten optimizar la relación agua/cemento efectivo, consiguiendo concretos más compactos y resistentes sin incrementar el contenido de cemento.

También se recalca la importancia de los aditivos minerales, así como la ceniza volcánica, el humo de sílice, las escorias granuladas y las puzolanas naturales. Estos materiales tienden a reaccionar al contar con el hidróxido de calcio liberado durante la hidratación, así consiguiendo la formación de compuestos secundarios de C-S-H que mejoran la microestructura del concreto y favorecen su durabilidad frente a los ataques químicos (Thomas, 2013).

“Las adiciones minerales bien dosificadas pueden reducir la permeabilidad, aumentar la resistencia a largo plazo y mejorar la durabilidad del concreto más que un simple incremento de cemento Portland” (Thomas, 2013, p. 223).

3.2.3.5. Proceso de mezclado, compactación y curado

Citando a Kosmatka et al. (2016) indica que el proceso del mezclado debe garantizar una correcta distribución uniforme en todos los componentes, para así evitar una segregación y lograr la consistencia homogénea adecuada. También indica que una mezcla insuficiente tiende a generar zonas con diferentes contenidos de cemento, lo que produce una variabilidad en la resistencia del concreto. Además, el tiempo del mezclado y el proceso de incorporación de los materiales deben ser adecuados según el tipo de mezcladora y la humedad de los agregados.

También se resalta la importancia de la compactación, cuya función principal es la de eliminar los vacíos atrapados de aire, los cuales reducen el área efectiva de aplicación de la carga. La vibración mecánica es el método más empleado y generalizado, su duración debe ser suficiente para conseguir la densidad máxima adecuada sin provocar la segregación. Además, el curado influencia decisivamente en el desarrollo de la resistencia bajo un ambiente húmedo y una temperatura estable donde permita la hidratación continua del cemento. Según el ACI 308R-16 donde se recomienda mantener la superficie del concreto húmeda por lo menos durante los primeros 7 días después del vaciado.

“La resistencia obtenida en el laboratorio raramente se replica en obra si no se controla la compactación y el curado; ambos procesos son tan importantes como la calidad de los materiales” (Neville, 2011, p. 341).

3.2.3.6. Normas técnicas peruanas e internacionales

De acuerdo con Mehta y Monteiro (2014) un correcto uso de la normativa no solo permite comparar resultado entre laboratorios, sino también asegurar una adecuada trazabilidad y reproducibilidad de los ensayos. Para el caso de investigaciones, el uso de la normativa NTP y ASTM asegura la validez tanto nacional e internacional de los resultados.

El control de la calidad del concreto se rige bajo las normas técnicas, que no solo garantizan su adecuado desempeño estructura sino la misma calidad de su elaboración, en el Perú tenemos las siguientes normativas:

- Norma Técnica Peruana-NTP 339.034
- Norma E.060 del reglamento nacional de edificaciones

Donde se establecen los procedimientos de ensayo y valores mínimos para la resistencia en distintos casos estructurales.

A nivel internacional, las normas que rigen el control son las:

- ASTM C39/C39M (Resistencia a compresión)
- ASTM C143 (Consistencia)
- ASTM C192 (Elaboración y curado de probetas de concreto)
- ACI 211 (diseño de mezcla de concreto)
- ACI 214 (Guía de evaluación estadística de resultados de concreto)

3.2.5 Redes Neuronales Artificiales

Las redes neuronales artificiales (RNA) son prototipos informáticos basados en el funcionamiento del cerebro humano. Están compuestos por neuronas artificiales, dispuestos en capas, que se conectan entre sí. Cada neurona recibe una entrada, se desarrolla a través de una función de activación la cual produce una salida. Las RNA son particularmente eficaces para resolver problemas complejos, donde la conexión de las variables no es lineal o es difícil de modelar de manera empírica. Estas redes son útiles en áreas como la predicción, el reconocimiento de patrones y el estudio de datos. Las RNA permiten establecer relaciones entre los parámetros de elaboración del concreto y la resistencia final a compresión, sin necesidad de fórmulas predefinidas (Haykin, 1998; Flood & Kartam, 1994; Zhang & Goh, 2016; Firat, 2017).

3.2.6 Modelo de Redes Neuronales

Hay diferentes tipos de redes neuronales, pero para la predicción de la resistencia del concreto, se utilizan principalmente redes neuronales feedforward (FFNN) y redes neuronales

multicapa (MLP). Las redes feedforward son las más básicas, donde los datos fluyen en un solo sentido, desde la capa de entrada hasta la de salida. Las redes multicapa incluyen una o más capas ocultas que permiten capturar relaciones no lineales entre las variables. En estos modelos, la red aprende a ajustar los pesos de los vínculos entre neuronas a través de un desarrollo iterativo, mejorando la precisión de las predicciones (Cheng et al., 2014; Russell & Norvig, 2021).

a) Perceptrón multicapa (MLP)

Es un modelo de red neuronal feedforward, donde las neuronas se disponen en capas: una capa de entrada, una o más capas ocultas, y una capa de salida. Cada neurona en una capa estará interconectada con la capa siguiente de neuronas. Este modelo es eficaz para la resolución de problemas complejos y no lineales gracias a las funciones de activación no lineales en las capas intermedias u ocultas (Goodfellow et al., 2016; Kumar & Roy, 2020).

Estructura:

- **Capa de entrada:** Obtiene los datos de entrada, que son parámetros de fabricación del concreto.
- **Capas ocultas:** Procesan las entradas mediante una combinación de pesos y funciones de activación. Pueden tener múltiples capas ocultas para capturar relaciones más complejas.
- **Capas de salida:** Produce el valor final predicho.

Ecuaciones:

- **Cálculo de la entrada neta de una neurona:**

La entrada neta de una neurona en una capa oculta se muestra en la siguiente ecuación:

Ecuación 1

Cálculo de entrada de Proceso de información de una neurona artificial

$$z_j = \sum_{i=1}^n w_{ij}x_i + b_j \quad (1)$$

En el cual z_j es la entrada neta en la neurona j , w_{ij} es el peso del vínculo entre la neurona i de la anterior capa y la neurona j (capa oculta), S son las variables aleatorias que representan la resistencia y el efecto de carga, respectivamente, x_i es la entrada de la neurona i , y b_j también conocida como sesgo asociado a la neurona j .

- **Función de activación:**

Usualmente la función sigmoide o ReLU. La función sigmoide se muestra en la siguiente ecuación:

Ecuación 2

Función de activación de RNA

$$a_j = f(z_j) = \frac{1}{1 + e^{-z_j}} \quad (2)$$

La función ReLu:

Ecuación 3

Función de activación tipo ReLU

$$a_j = f(z_j) = \max(0, z_j) \quad (3)$$

El valor de a_j es la salida de la neurona j .

Figura 1*Función de activación ReLU*

Nota: Grafico elaborado de modelo de RNA por el autor

Es la que nos permite un entrenamiento más eficiente en redes neuronales artificiales mas profundas.

- Cálculo del error:

El fallo para la modificación de los pesos se calculó con la siguiente ecuación:

Ecuación 4

Cálculo de error o loss de RNA

$$E = \frac{1}{2} \sum_{k=1}^m (y_k - \widehat{y}_k)^2 \quad (4)$$

Donde E es el error cuadrático medio, y_k es el valor verdadero de la resistencia a compresión, $\widehat{y}_k$ es el valor predicho.

- Ajustes de los pesos:

Utilizando el descenso por gradiente:

Ecuación 5

Ajuste de pesos en cada neurona artificial


$$w_{ij}^{t+1} = w_{ij}^t - n \frac{\partial E}{\partial w_{ij}} \quad (5)$$

Donde n es la tasa de aprendizaje y $\frac{\partial E}{\partial w_{ij}}$ es la gradiente del error respecto al w_{ij} .

La Figura 2 muestra un esquema de un perceptrón multicapa con función de transferencia sigmoidea.

Figura 2

Esquema de un perceptrón multicapa.



Nota: Grafico tomado de (Acuña et al., 2014).

b) Red de Elman

Es una clase de red neuronal demandada que incluye conexiones hacia atrás que permiten el modelado de secuencias temporales y dependencias a largo plazo. Esto la diferencia de las redes feedforward, ya que tiene memoria interna que puede recordar información anterior, lo que la hace útil para problemas dinámicos o basados en secuencias (Tino et al., 2017).

Estructura:

- **Capa de entrada:** Recibe las entradas externas.

- **Capas ocultas:** Procesa la información de la capa de entrada y también recibe su propio estado anterior, lo que permite a la red mantener un historial o contexto de los datos pasados.
- **Capas de contexto:** Esta capa almacena los estados anteriores de la capa oculta y los retroalimenta en el siguiente paso de tiempo.
- **Capas de salida:** Genera la salida final.

Ecuaciones:

- **Estado de la capa oculta:**

El estado de la capa oculta en la red de Elman se calcula con la siguiente ecuación:

Ecuación 6

Estado de la hidden layer según Elman

$$h_t = f(W_h x_t + U_h h_{t-1} + b_h) \quad (6)$$

Donde h_t es el estado de la capa oculta en el tiempo t , W_h es el peso asociado a la entrada x_t en el tiempo t , U_h es el peso de la retroalimentación desde el estado anterior h_{t-1} , b_h es el sesgo de la capa oculta, f es la función de activación.

- **Estado de la capa de salida:**

Se calcula con la siguiente ecuación:

Ecuación 7

Estado de la capa de salida

$$y_t = f(W_y h_t + b_y) \quad (7)$$

Donde y_t es la salida en el tiempo t , W_y es el peso indicando la capa oculta hacia la capa de salida, b_y conocido como sesgo de la capa de salida.

- **Actualización del estado de contexto:**

La red de Elman usa el estado oculto anterior h_{t-1} como capa de contexto, que se retroalimenta en cada paso con la siguiente ecuación:

Ecuación 8

Retroalimentación de las neuronas artificiales


$$c_t = h_{t-1} \quad (8)$$

Esta retroalimentación permite que la red capture patrones a lo largo del tiempo, lo que es crucial en problemas secuenciales.

La Figura 3 muestra una red Elman con función de transferencia sigmoidea.

Figura 3

Red de Elman



Nota: Grafico tomado de (Acuña et al., 2014).

3.2.7 Entrenamiento de la Red

El procedimiento de preparación de cada red neuronal consiste en ajustar los pesos y sesgos de las conexiones internas de la red para que el modelo sea apto de predecir con exactitud la resistencia a compresión del concreto. Este entrenamiento se realiza mediante redes de optimización, descenso por gradiente, que suelen requerir un conjunto de datos de preparación, que incluye ejemplos históricos de mezclas de concreto y sus respectivas resistencias. El backpropagation es un algoritmo clave que ajusta los pesos en función del error de la predicción. Un buen entrenamiento requiere evitar problemas como el sobreajuste (overfitting), donde el modelo se adapta en exceso a los datos de preparación y pierde el potencial de generalización (Tino et al., 2017).

3.2.8 Optimizador Adam

Este optimizador conocido como Adam (Adaptive Moment estimation) no es más que un algoritmo de optimización estocástico, que se encarga de ajustar los pesos de una red neuronal manejando estimaciones adaptadas a momentos de un primer o segundo orden de la gradiente. Esta combina las diferentes ventajas de los métodos Adagrad y RMSProp, así proporcionándonos una convergencia mucho más fluida, rápida y estable en problemas con datos dispersos o más ruidosos (Kingma & Ba, 2015).

3.2.9 Función de pérdida o loss Function

Según Goodfellow, Bengio, & Courville (2016) quienes indican que la función de pérdida se encarga de cuantificar el error entre las salidas predichas y los valores reales esperados realizados por el modelo, manejando el proceso de aprendizaje a través de la minimización

iterativa del error. Los diferentes modelos de regresión comparten la función más común la cual es el error cuadrático medio (mean squared error, MSE), que se encarga de penalizar las diferencias cuadráticas entre los diferentes valores reales y los estimados.

- Métricas de desempeño de los modelos

Tenemos 3 tipos los cuales son bien usados en estos modelos:

1.- El coeficiente de determinación (R^2) el cual se encarga de medir el grado de ajuste entre los diferentes valores reales y predichos

2.- Error cuadrático medio (RMSE) el cual se encarga de representar la raíz cuadrada del promedio de los errores al cuadrado.

3.- Error absoluto medio (MAE) el cual se encarga de cuantificar el promedio de las diferencias absolutas

3.2.10 Coeficiente r de Pearson

De acuerdo con Hair et al. (2019) quien nos indica que el coeficiente de correlación de Pearson se enfoca en medir la fuerza y dirección de la relación lineal entre dos variables, esto fundamentalmente para comprender los patrones en el análisis de datos multivariados. Este coeficiente adopta valores entre -1 y +1, donde +1 indica una correlación positiva perfecta, mientras que -1 nos indica una correlación negativa perfecta, y 0 una ausencia de la relación lineal.

La correlación se calcula con el coeficiente de Pearson (r) definido en la siguiente ecuación:

Ecuación 9

Coeficiente de r de Pearson

$$r_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}}$$

Donde r_{xy} representa el coeficiente de correlación entre las variables x e y ; $\bar{x}$ y $\bar{y}$ son las medias aritméticas.

3.3 Definición de términos

Red Neuronal Artificial (RNA): Sistema de procesamiento de datos basados en el cerebro humano, formado por capas de neuronas artificiales que analizan datos y generan salidas sustentados en patrones aprendidos. En este proyecto, se utiliza para anticipar la resistencia del concreto en función a sus componentes (Zhang & Goh, 2016).

Modelo Predictivo: Esquema matemático o computacional que, basado en datos de entrada, genera una salida que predice un fenómeno futuro. En esta situación, se intenta anticipar la resistencia a compresión del concreto a los 28 días (Haykin, 1998).

Entrenamiento de la Red Neuronal: Proceso mediante el cual la red modifica sus variables internas para reducir el error en las predicciones. Utiliza un conjunto de datos para aprender las relaciones entre los parámetros de entrada y salida (Flood & Kartam, 1994).

Resistencia a Compresión del Concreto: Aptitud del concreto para soportar cargas de compresión, medida típicamente a los 28 días de curado. Es el indicador más importante de la calidad estructural del material (Aquino, 2019).

Parámetros de Fabricación del Concreto: Variables que influyen en la mezcla y proceso de fabricación del concreto, como la proporción de agua/cemento, tipo de agregados, propiedades de curado, y aditivos. Estos parámetros afectan directamente la resistencia final (Otazzino Pasino, 2016).

Perceptrón: Consiste en una sola neurona con múltiples entradas que se ponderan mediante pesos asociados. Su salida se obtiene al aplicar una función de activación a la suma ponderada de las entradas (Goodfellow et al., 2016).

Función de transferencia: Conocida como Función de Activación, es un cálculo matemático realizado sobre la salida de una neurona para determinar si ésta debe activarse (disparar una señal) o no (Tino et al., 2017).

IV. Metodología

4.1 Tipo y Nivel de investigación

Se plantea la investigación, de acuerdo con nuestro objetivo, el estudio es de tipo aplicada, ya que su propósito es teórico-práctico. Carrasco Diaz (2006) indica que se investigan teorías y métodos científicos para generar avances en un área específica, con el fin de proponer un modelo predictivo que permita determinar con precisión la resistencia a compresión del concreto de construcción a los 28 días utilizando redes neuronales artificiales. Esto facilitaría la toma de decisiones rápidas, reduciría los tiempos de espera y disminuiría los costos asociados. Además, este enfoque tiene un impacto potencialmente significativo no solo en el sector de la construcción de la ciudad de Abancay, sino también a nivel nacional e internacional.

La presente investigación está planteada bajo el enfoque cuantitativo, pues se fundamenta en la recolección y su correspondiente análisis de datos, utilizando métodos estadísticos y modelos computacionales. Con este estudio se busca explicar y predecir el comportamiento de la resistencia a compresión del concreto a partir de sus parámetros de fabricación y bajo las condiciones atmosféricas registradas durante el curado.

Bajo el criterio de Hernandez Sampeire, Fernandez y Baptista (2022), el tipo de investigación para este proyecto es aplicada, ya que tiene como finalidad aportar una solución práctica a los problemas técnicos en el ámbito de la ingeniería civil: optimizar el control de la calidad del concreto mediante herramientas de inteligencia artificial. Durante la ejecución de esta investigación se utilizó fundamentos técnicos y metodológicos para el desarrollo de un modelo predictivo de utilidad directa en el campo constructivo.

Mientras que el nivel de investigación se considera correlacional y predictivo, debido a que se busca determinar el grado de relación entre los parámetros de fabricación y las variables atmosféricas, con la resistencia a compresión del concreto. Además, mediante el uso de la RNA se busca predecir dichas resistencias con base a los datos obtenidos.

De esta manera el estudio se puede considerar en el nivel correlación-predictivo, ya que nos permite identificar asociaciones estadísticas, desarrollar un modelo capaz de estimar el comportamiento mecánica del concreto en función de las condiciones específicas de producción y ambiente.

4.1.1 Diseño de investigación

La presente investigación adopta un enfoque cuantitativo orientada al desarrollo de un modelo predictivo de la resistencia a compresión del concreto en base a los parámetros de fabricación.

El diseño de investigación es no experimental, de tipo longitudinal y su alcance es correlacional predictivo, esto debido a que las variables independientes no fueron manipuladas deliberadamente, sino observadas bajo condiciones controladas de laboratorio y ambientales.

Se procedió a la elaboración de 233 probetas cilíndricas de concreto esto bajo el procedimiento normativo del método ACI 211, manteniendo constantes los parámetros de fabricación. Luego se procedió a someter a ensayo de compresión a las probetas cilíndricas a los 7, 14 y 28 días conforme a la normativa vigente, registrando la resistencia promedio de cada tanda.

De forma complementario se recolecto variables atmosféricas del periodo de curado, esto mediante fuentes meteorológicas, específicamente la temperatura relativa media, las cuales fueron asociadas temporalmente a cada muestra. Estas variables ambientales se incorporaron a la

base de datos como predictores adicionales, al reconocerse su importante influencia dentro del proceso de hidratación y ganancia de la resistencia del concreto (Zhu et al, 2021; Qayyun et al, 2023).

4.2 Ámbito temporal y espacial

- Ámbito Temporal

El estudio se llevó a cabo durante el año 2024 y 2025, comprendiendo el periodo de elaboración de la RNA de septiembre del 2024 a agosto del 2025 para el entrenamiento de la RNA, y el segundo periodo comprendido de enero a junio del 2025 para la recolección de los datos de briquetas elaboradas para esta tesis.

- Ámbito espacial

La investigación se desarrolló en el laboratorio de Suelos, Concreto y Pavimentos Lunix Ingenieros S.R.L, ubicado en la ciudad de Abancay, región de Apurímac, Perú. Este entorno nos permitió la obtención directa de los datos experimentales que fueron elaboradas bajo condiciones controladas de laboratorio.

4.3 Población y muestra

4.3.1 Población

Según Carrasco Díaz (2006), la población de una investigación está constituida por el conjunto de elementos o unidades de análisis que comparten características comunes y que se encuentran dentro del ámbito donde se desarrolla el estudio. En la investigación, la población está conformada por las probetas de concreto elaboradas y ensayadas a compresión en la ciudad de Abancay, considerando aquellas que cuentan con información técnica sobre sus parámetros de fabricación y resistencia mecánica.

De manera específica, la población comprende las probetas de concreto sometidas a ensayos de resistencia a compresión a los 28 días, elaboradas en laboratorios universitarios, centros de ensayo locales y laboratorios especializados de la ciudad de Abancay. Estas probetas corresponden a mezclas producidas bajo condiciones controladas, con diferentes dosificaciones, relaciones agua/cemento, características de agregados, condiciones de curado y parámetros ambientales. Por ello, dicha población constituye el universo de datos experimentales relacionados con el comportamiento resistente del concreto local, los cuales sirven como base para el desarrollo de un modelo predictivo mediante redes neuronales artificiales.

4.3.2 Muestra

Según Rojas (2011), la muestra constituye una parte o segmento de la población sobre la cual se recolectan los datos necesarios para el desarrollo del estudio. En la presente investigación, la muestra está conformada por 687 probetas de concreto, 234 datos elaborados por el autor y 454 datos recopilados de investigaciones realizadas en la ciudad de Abancay, seleccionadas bajo un

muestreo no probabilístico de tipo intencional, debido a que las unidades de análisis fueron incorporadas en función de su disponibilidad, pertinencia técnica y cumplimiento de criterios relacionados con los objetivos de la investigación.

Las probetas consideradas en la muestra corresponden a especímenes de concreto sometidos a ensayos de resistencia a compresión, cuyos datos permiten relacionar los parámetros de fabricación del concreto con su resistencia mecánica. La selección de estas unidades se justifica porque el estudio no busca estimar proporciones poblacionales mediante encuestas, sino construir un modelo predictivo basado en datos experimentales. En ese sentido, la representatividad de la muestra se fundamenta en la calidad, consistencia y pertinencia de los registros utilizados para el entrenamiento, validación y prueba del modelo de red neuronal artificial.

Las muestras de la investigación están conformadas por 687 registros de ensayos de resistencia a la compresión del concreto realizados en la ciudad de Abancay desde el año 2016 hasta el 2024. Esta cantidad de muestra se obtuvo bajo un enfoque de muestreo por conveniencia, correspondientes a las probetas elaboradas bajo las condiciones controladas en el Laboratorio de Suelos, Concreto y Pavimentos Lunix Ingenieros S.R.L, siguiendo los procedimientos establecidos en la normativa vigente (ACI 211 y NTP 339.0.34). Por otro lado, los demás registros restantes conformado por 454 muestras se obtuvieron mediante el muestreo intencional, a partir de la recopilación de datos experimentales de tesis de pregrado desarrolladas en la ciudad de Abancay. Para su inclusión en la base de datos, se aplicaron 3 criterios de selección:

- 1) Las tesis deben contener datos completos de los parámetros de fabricación del concreto (relación a/c, dosificación de materiales, lugares de curado, fechas etc.).
- 2) Los ensayos de resistencia a compresión debían haberse realizado conforme a la normativa NTP 339.034.

- 3) Las muestras debían provenir de mezclas elaboradas con materiales locales de la ciudad de Abancay.
- 4) Las variables numéricas continuas fueron normalizadas en el rango $[0, 1]$ mediante la técnica `MinMaxScaler`, con el fin de mejorar la convergencia del modelo y evitar que las variables de mayor magnitud distorsionen el aprendizaje, esto se hará durante la ejecución final del código para que se depure bajo las condiciones de la base de datos.

Para garantizar una adecuada escala de los datos durante el entrenamiento del modelo de red neuronal artificial, se aplicó la técnica de normalización `MinMaxScaler`. Esta técnica transforma las variables continuas al rango $[0, 1]$, preservando las proporciones relativas entre valores sin distorsionar su distribución.

En la implementación, se utilizó la función `MinMaxScaler()` de la biblioteca `Scikit-learn`, aplicada al conjunto de entrenamiento (`X_train_clean`) mediante el método `fit_transform()`, como se muestra en el siguiente fragmento de código:

```
scaler_cv = MinMaxScaler()
```

```
X_train_scaled = scaler_cv.fit_transform(X_train_clean)
```

Esta transformación permitió acelerar el proceso de aprendizaje del modelo, mejorar la estabilidad numérica durante la retropropagación y evitar que variables con mayor magnitud dominaran el proceso de ajuste de pesos.

De esta manera la integración de los datos, garantizo una muestra representativa y robusta del comportamiento del concreto local, asegurando la homogeneidad, la relevancia y la suficiente variabilidad necesaria para el entrenamiento, validación y evaluación del modelo de RNA creado para esta investigación.

4.4 Instrumentos

4.4.1 Técnicas

De acuerdo con Carrasco Díaz (2006), las técnicas son pautas que nos guían en las actividades llevadas a cabo en las diferentes etapas de la investigación. Estas técnicas son herramientas que se utilizan para seguir procedimientos, y para su uso y aplicación es necesario contar con un conocimiento previo. En esta investigación se empleará la técnica de recolección de información mediante análisis documental, la cual se apoyará en normativas, reglamentos, investigaciones indexadas y libros relacionados con el objetivo de proponer un modelo predictivo basado en ensayos experimentales de resistencia a compresión del concreto, empleando redes neuronales artificiales. Además, se recopilará información experimental en laboratorio, basada en pruebas de resistencia a la compresión del concreto de construcción.

4.4.2 Instrumento

Carrasco Díaz (2006) afirma que los instrumentos son indispensables en la recolección de datos y deben aplicarse según las características del problema para luego ser analizados, procesados y transformados en conocimiento. En esta investigación se incluirá la medición de datos en laboratorio, para lo cual se utilizarán fichas técnicas como herramienta de recolección de datos, apoyadas en normativas como la NTP 339.034 y el Reglamento Nacional de Edificaciones. Se debe tomar en cuenta que tanto los instrumentos digitales como los físicos, diseñados exclusivamente para recopilar información relacionada con el objetivo de la investigación, serán utilizados como herramientas de acumulación de datos.

Instrumento de validación para recolección de datos de tesis consultadas

[illegible]

Nota: Instrumento de recolección elaborado por el autor

Nota: Instrumento de recolección elaborado por el autor.

4.5 Procedimientos

- Procedimientos y depuración del dataset

El desarrollo de esta investigación se realizó a través el diseño correlacional-predictivo, según la clasificación sugerida por Sampieri et al. (2018), que permitió el análisis de las relaciones entre las variables de fabricación del concreto y la resistencia mecánica, e implementar un sistema predictivo enfocado en las redes neuronales artificiales para la predicción de valores de resistencia.

La investigación se ejecutó en cuatro etapas secuenciales, estas fueron diseñadas para garantizar la rigurosidad científica, validez estadística y la réplica del modelo propuesto para la predicción.

a) Primera etapa: Elaboración de probetas de concreto y validación de resultados

Figura 7

Pruebas de ensayos a los agregados grueso y fino



Nota: Imágenes tomadas por el autor

Tabla 2
Resultado de ensayos de agregado fino y grueso

CANTERA MURILLO			
AGREGADOS	A_GRUESO	A_FINO	UND
Peso unitario suelto seco	1403.39	1451.78	kg/m ³
Peso unitario compactado seco	1594.83	1797.68	kg/m ³
Peso específico del agregado grueso	2710	2740	kg/m ³
Porcentaje de absorción	1.08	1.59	%
Contenido de Humedad	0.13	4.4	%
Módulo de fineza	6.8	3.02	
Tamaño máximo nominal	1/2	-	

Nota: Esta tabla muestra los resultados de los agregados

- Diseño por el método ACI 211

Datos generales:

Resistencia de concreto = 210 kg/cm²

Densidad del agua = 1000 kg/m³

Cemento Yura T1 = 3150 kg/m³

Slump = 3 – 4 pulg

1) Resistencia a compresión requerida

$$f'_c = 210 \text{ kg/cm}^2$$

Tabla 3
Resistencia a compresión requerida

Tabla de diseño	
f'_c	f'_{cr}
<210	$f'_c + 70$
210 a 350	$f'_c + 84$
>350	$f'_c + 98$

Nota: Tabla para la elaboración del diseño de mezcla

$$f'_{cr} = 294 \text{ kg/cm}^2$$

2) Selección del asentamiento

Tabla 4
Selección de asentamiento

Tabla de diseño			
Consistencia	Slump	Trabajabilidad	Método de compactación
SECA	0'' a 2''	Poco trabajable	Vibración normal
PLASTICA	3'' a 4''	Trabajable	Vibración ligera chuseado
FLUIDA	>5''	Muy Trabajable	Chuseado

Nota: Tabla para la elaboración del diseño de mezcla

Se trabajará con slump de 3'' a 4'' con consistencia plástica

3) Contenido de aire atrapado

Tabla 5
Contenido de aire atrapado

Tabla de diseño	
Contenido de aire atrapado TMN de agregado grueso	Aire atrapado
3/8"	3.00%
1/2"	2.50%
3/4"	2.00%
1"	1.50%
1 1/2"	1.00%
2"	0.50%
3"	0.30%
4"	0.20%

Nota: Tabla para la elaboración del diseño de mezcla

Se obtiene:

Aire atrapado = 2.50%

4) Volumen unitario de agua

Tabla 6

Volumen unitario de agua

Tabla de diseño								
VOLUMEN UNITARIO DE AGUA								
Asentamiento	Agua, en 1/m ³ , para los tamaños max nominales de agregado grueso y consistencias indicados							
	3/8"	1/2"	3/4"	1"	1 1/2"	2"	3"	6"
	Concretos sin aire incorporado							
1" a 2"	207	199	190	179	166	154	130	113
3" a 4"	228	216	205	193	181	169	145	124
6" a 7"	243	228	216	202	190	178	160	

Nota: Tabla para la elaboración del diseño de mezcla

Tenemos:

Slump = 3" a 4"

TMN = 1/2"

Obtendremos:

Volumen unitario de agua = 216 lt/m³

5) Relación agua/cemento (a/c)

Tabla 7

Relación agua/cemento (a/c)

Tabla de diseño

RELACION AGUA/CEMENTO POR RESISTENCIA		
f'cr (Kg/cm ²)	Relación agua/cemento en peso	
	Concretos sin aire incorporado	Concretos con aire incorporado
150	0.8	0.71
200	0.7	0.61
250	0.62	0.53
300	0.55	0.46
350	0.48	0.4
400	0.43	-
450	0.38	-

Nota: Tabla para la elaboración del diseño de mezcla

Para un $f'_{cr} = 294 \text{ kg/cm}^2$ para concretos sin aire incorporado

Se hará uso de la interpolación:

$$y = y_0 + \frac{y_1 - y_0}{x_1 - x_0}(x - x_0)$$

300	0.55
294	y
250	0.62

$$y = 0.55 + \frac{0.62 - 0.55}{250 - 300}(294 - 300)$$

$$y = 0.558$$

$$a/c = 0.558 \approx 0.56$$

6) Factor cemento

$$C = \frac{\text{Volumen unitario de agua}}{\text{Relacion agua/cemento}}$$

$$C = \frac{216}{0.56}$$

$$C = 385.71 \text{ kg}$$

Una bolsa de cemento pesa = 42.5 kg

$$\text{Factor cemento} = \frac{385.71}{42.5}$$

$$\text{Factor cemento} = 9.08 \text{ Bol/m}^3$$

7) Contenido del agregado grueso

Tabla 8

Contenido de agregado grueso

Tabla de diseño				
PESO DEL AGREGADO POR UNIDAD DE VOLUMEN DEL CONCRETO				
TMN del agregado grueso	Vol. De agregado grueso, seco y compactado, por unidad de volumen del concreto, para diversos módulos de fineza			
	2.4	2.6	2.8	3
3/8"	0.5	0.48	0.46	0.44
1/2"	0.59	0.57	0.55	0.53
3/4"	0.66	0.64	0.62	0.6
1"	0.71	0.69	0.67	0.65
1 1/2"	0.76	0.74	0.72	0.7
2"	0.78	0.76	0.74	0.72
3"	0.81	0.79	0.77	0.75
6"	0.87	0.85	0.83	0.81

Nota: Tabla para la elaboración del diseño de mezcla

Tenemos:

TMN = 1/2"

Módulo de fineza = 3.02

Por consecuencia tenemos

Volumen agregado grueso seco-compactado=0.53

- Peso del agregado grueso seco

$$\text{Peso Ag. grueso seco} = \text{Vol. Ag. Grueso seco compactado} * \text{Peso uni. sec. compactado}$$

$$\text{Peso Ag. grueso seco} = 0.53 * 1594.83$$

$$\text{Peso Ag. grueso seco} = 845.26 \text{ kg/m}^3$$

8) Volumen absoluto

- Cemento

$$\text{Vol. Cemento} = \text{Peso de cemento} / \text{Peso especifico}$$

$$\text{Vol. Cemento} = 385.71 / 3150$$

$$\text{Vol. Cemento} = 0.122 \text{ m}^3$$

- Agua

$$\text{Vol. Agua} = \text{Peso de agua} / \text{Peso especifico}$$

$$\text{Vol. Cemento} = 216 / 1000$$

$$\text{Vol. Cemento} = 0.216 \text{ m}^3$$

- Aire

$$\text{Vol. Agua} = 0.025$$

- Ag. grueso

$$\text{Vol. Agua} = \text{Peso de agua} / \text{Peso especifico}$$

$$\text{Vol. Cemento} = 845.26 / 2710$$

$$Vol. Cemento = 0.312 m^3$$

Contenido total de volúmenes:

Cemento	0.122
Agua	0.216
Aire	0.025
Grueso	0.312
Suma	0.675

- Ag. fino

$$Vol. fino = 1 - 0.675$$

$$Vol. fino = 0.325 m^3$$

- *Calculo del peso del agregado fino*

$$Peso agregado fino = \frac{Vol. fino}{Peso especifico Ag. fino}$$

$$Peso agregado fino = \frac{0.325}{2740}$$

$$Peso agregado fino = 889.53 kg$$

9) Diseño de mezcla en seco

Tabla 9

Diseño de mezcla en seco

Cemento	385.714	Kg/m ³
A. fino	889.533	Kg/m ³
A. grueso	845.260	Kg/m ³
Agua	216.000	Kg/m ³

Nota: Tabla para la elaboración del diseño de mezcla

10) Corrección por humedad de los agregados

- Para agregado fino

$$Ag. fino = Peso seco * \left(\frac{W\%}{100} + 1 \right)$$

$$Ag. fino = 889.533 * \left(\frac{4.4}{100} + 1\right)$$

$$Peso humedo Ag. fino = 928.672 \text{ kg/m}^3$$

- Para agregado grueso

$$Ag. grueso = Peso seco * \left(\frac{W\%}{100} + 1\right)$$

$$Ag. grueso = 845.26 * \left(\frac{0.13}{100} + 1\right)$$

$$Peso humedo Ag. grueso = 846.359 \text{ kg/m}^3$$

11) Aporte de agua para la mezcla

- Para agregado fino

$$Agua en Ag. fino = \frac{(W\% - abs\%) * Ag. fino Seco}{100}$$

$$Agua en Ag. fino = \frac{(4.4 - 1.59) * 889.533}{100}$$

$$Ag. fino = 26.096 \text{ lt/m}^3$$

- Para agregado grueso

$$Agua en Ag. grueso = \frac{(W\% - abs\%) * Ag. grueso Seco}{100}$$

$$Agua en Ag. grueso = \frac{(0.13 - 1.08) * 845.26}{100}$$

$$Ag. grueso = -8.04 \text{ lt/m}^3$$

$Suma total de agua en Ag. Grueso + Ag. fino = 18.055 \text{ lt/m}^3$

- Agua efectiva

$$Agua efectiva = 216 - 18.055$$

$$Agua efectiva = 197.945 \text{ lt/m}^3$$

12) Proporciones finales de diseño

Tabla 10

Diseño de mezcla final

Cemento (Kg)	A_fino (Kg)	A_grueso (Kg)	Agua (lt)
385.714	928.672	846.359	197.945

Nota: Tabla para la elaboración del diseño de mezcla

Se hará una corrección por desperdicio del 5%

Tabla 11

Diseño de mezcla final agregando desperdicio

Cemento (Kg)	A_fino (Kg)	A_grueso (Kg)	Agua (lt)
405.000	975.106	888.677	207.842

Nota: Tabla para la elaboración del diseño de mezcla

Figura 8

Proceso de producción y rotura de briquetas de concreto



Nota: Imágenes tomadas por el autor

b) Segunda etapa: Recolección y organización de los datos experimentales

La segunda etapa consistió en la recolección, obtención y sistematización de los datos experimentales relacionados directamente con las propiedades del concreto y su resistencia a compresión. La recolección de los datos se realizó a través de consultas de fuentes documentales (Tesis), complementadas con ensayos experimentales propios, conformando un diseño mixto de recolección que no solo garantizo la representatividad si no también la consistencia de los datos de la ciudad de Abancay.

Los datos reunidos tanto experimentales, así como registros documentados (Tesis) generaron una base compuesta de 687 datos representativos, 233 fueron datos elaborados para este proyecto de tesis, mientras que los 454 datos restantes fueron datos recopilados de proyectos de tesis realizados siguiendo la metodología ACI 211 de diseño de mezcla de concreto en la ciudad de Abancay. Además, que esta información conseguida fue previamente revisada y consolidada con el fin de obtener datos de calidad y no agregar un posible ruido durante el entrenamiento del modelo de RNA. Las fuentes consultadas fueron tesis elaborados en la Universidad Tecnológica de los Andes y la Universidad Nacional Micaela Bastidas de Apurímac, tesis elaboradas durante el periodo del 2016 hasta la fecha 2024.

Estos datos fueron consolidados con las siguientes características:

- Fecha de elaboración y rotura de briquetas
- Diseños de mezcla
- Edad
- Densidad de diseño
- Aditivos

- Ensayos de agregados fino y grueso

Teniendo como variable de salida:

- Resistencia de compresión del concreto

Tabla 12

Registro de información de tesis consultadas para recolección de datos

N°	REGISTRO DE INFORMACION	AUTOR/S	Datos
1	REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL CONCRETO DE CONSTRUCCIÓN A PARTIR DE SUS PARÁMETROS DE FABRICACIÓN EN LA CIUDAD DE ABANCAY-2024	PALOMINO VALENZUELA JANIO IGNACIO	233
2	ESTUDIO COMPARATIVO EN LA AUTOCONSTRUCCIÓN DE EDIFICACIONES UTILIZANDO CONCRETO AUTOCOMPACTANTE CON LA INCORPORACIÓN DE ADITIVO SUPERPLASTIFICANTEFRENTE AL CONCRETO CONVENCIONAL REALIZADOS EN LA CUIDAD DE ABANCAY	QUISPE MUNARES JOSÉ AUGUSTO MOSQUEIRA SULLCAHUAMÁN CRISTHANS	60
3	ESTUDIO DEL DISEÑO DE MEZCLA CON CEMENTO TIPO HE Y DISEÑO DE MEZCLA CON ADITIVO Z FRAGUA #5 PARA ACELERAR LA RESISTENCIA INICIAL A LA COMPRESIÓN DEL CONCRETO F'C = 210 KG/CM2	JULIAN HERBERT, PALOMINO ROMAN	240
4	EFFECTOS DE LA ADICION DE FIBRA DE POLIESTER 40/2 EN LAS PROPIEDADES PLASTICAS Y MECANICAS EN COMPRESION AXIAL Y FLEXION CON DOSIFICACION OPTIMA DEL CONCRETO F'C 210 KG/CM2 ABANCAY APURIMAC 2019	CHIRINOS CCASA, JOSEPH	12
5	INFLUENCIA DE LA SUSTITUCIÓN PARCIAL DEL CEMENTO POR CENIZA DE AGAVE AMERICANO EN LAS PROPIEDADES MECÁNICAS DEL CONCRETO F'C =20.59 MPA, ABANCAY, APURÍMAC, 2020	PERCY CABALLERO PALOMINO	18
6	EVALUACIÓN DE LA RESISTENCIA A LA COMPRESIÓN Y FLEXOTRACCIÓN DEL CONCRETO ELABORADO CON CENIZA DE BAGAZO DE CAÑA DE AZÚCAR COMO SUSTITUTO PARCIAL DEL CEMENTO EN ABANCAY, 2019.	CARLOS YASMANY HUARACA HUAMÁN	12
7			9

	ANÁLISIS DE LA INFLUENCIA DE LA SUSTITUCIÓN PARCIAL DEL CEMENTO POR CENIZA DE RASTROJO DE ZEA MAYS L. EN LA RESISTENCIA MECÁNICA DE CONCRETO $f'c=24.5$ MPA, DISTRITO DE ABANCAY, PROVINCIA DE ABANCAY, REGIÓN APURÍMAC – 2020	YESENIA, JUAREZ TORVISCO	
8	INFLUENCIA DEL CURADO EN LA RESISTENCIA A LA COMPRESIÓN DEL CONCRETO PREPARADO CON CEMENTO PORTLAND TIPO I Y CEMENTO PUZOLÁNICO TIPO IP EN LA CIUDAD DE ABANCAY – APURIMAC	CUELLAR LOAIZA, JULIO CESAR SEQUEIROS ARONE, WALKER	72
9	INFLUENCIA DE LA ADICION DE FIBRAS SINTETICAS DE POLIPROPILENO EN LA RESISTENCIA AL AGRIETAMIENTO POR CONTRACCION PLASTICA Y LA RESISTENCIA A LA COMPRESION DEL CONCRETO $f'c=210$ KG/CM2 EN LOSAS ALIGERADAS ABANCAY 2021	YERLY ROSITA COLLADO QUISPE	16
10	INFLUENCIA DE LAS PROPIEDADES MECANICAS DEL CONCRETO $f'c=175$ KG/CM2 CON LA INCORPORACION DE PLASTICOS RECICLADOS (PET), ABANCAY, APURIMAC 2023	ALZAMORA CAILLAHUA NAYSHA	6
11	DETERMINACION DE LA RESISTENCIA A COMPRESION AXIAL DEL CONCRETO ESTRUCTURAL $f'c=210$ KG/CM2 INTEGRADO A LA MEZCLA COMO ADITIVO NATURAL EL MUCILAGO DE PENCA DE TUNA EN LA CIUDAD DE ABANCAY 2022	ASTRID AMBAR VALVERDE CORTEZ	9
	TOTAL		687

Nota: Contenido de tesis consultadas para la investigación, se incluye los resultados de los ensayos realizados para esta tesis.

Figura 9

Ejemplo de recolección de datos de las tesis citadas.

UNIVERSIDAD TECNOLÓGICA DE LOS ANDES																										
Facultad de Ingeniería																										
Ingeniería Civil																										
PROYECTO: REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL CONCRETO DE CONSTRUCCIÓN A PARTIR DE SUS PARÁMETROS DE FABRICACIÓN EN LA CIUDAD DE ABANCAY-2024																										
TESISTA: JANIO GINACIO PALOMINO VALENZUELA																										
Fecha de inicio	Fecha de rotura	Cemento (kg)	Agua (Litros)	Agregado fino (kg)	Agregado Grueso (kg)	Edad (días)	Superplastificante (kg)	Aditivo Acelerante (kg)	Densidad de cemento (kg/cm3)	Slump (pulg)	Densidad (kg/m3)	Peso unitario suelto seco (kg/m3)	Peso unitario compactado seco (kg/m3)	Peso específico del agregado fino (kg/m3)	Porcentaje de absorción (%)	Contenido de Humedad(%)	Modulo de fineza	Peso unitario suelto seco (kg/m3)	Peso unitario compactado seco (kg/m3)	Peso específico del agregado grueso (kg/m3)	Porcentaje de absorción (%)	Contenido de Humedad(%)	Modulo de fineza	Tamaño maximo nominal	Resistencia (kg/cm2)	
16/05/2025	23/05/2025	400	196.85	967.77	846.36	7	0	0	3150	3-4	2405.7	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	300.6	
16/05/2025	23/05/2025	400	196.85	967.77	846.36	7	0	0	3150	3-4	2354.5	1451.78	1797.68	2740.0	1.59	4.4	3.0	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	276.1	
16/05/2025	23/05/2025	400	196.85	967.77	846.36	7	0	0	3150	3-4	2355.0	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	269.6	
10/05/2025	24/05/2025	400	196.85	967.77	846.36	14	0	0	3150	3-4	2358.86	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	309.6	
10/05/2025	24/05/2025	400	196.85	967.77	846.36	14	0	0	3150	3-4	2369.45	1451.78	1797.68	2740.0	1.59	4.4	3.0	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	305	
10/05/2025	24/05/2025	400	196.85	967.77	846.36	14	0	0	3150	3-4	2366.57	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	305.9	
26/04/2025	25/05/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2380.19	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	355.6	
26/04/2025	25/05/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2343.50	1451.78	1797.68	2740.0	1.59	4.4	3.0	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	369.5	
26/04/2025	25/05/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2392.81	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	388.4	
6/05/2025	3/06/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2424.69	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	366.7	
6/05/2025	3/06/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2399.42	1451.78	1797.68	2740.0	1.59	4.4	3.0	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	367.6	
6/05/2025	3/06/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2351.60	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	349.7	
1/05/2025	29/05/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2376.55	1451.78	1797.68	2740.0	1.59	4.4	3.0	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	357.8	
1/05/2025	29/05/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2388.48	1451.78	1797.68	2740.0	1.59	4.4	3.02	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	361.9	
1/05/2025	29/05/2025	400	196.85	967.77	846.36	28	0	0	3150	3-4	2377.64	1451.78	1797.68	2740.0	1.59	4.4	3.0	1403.39	1594.83	2710	1.08	0.13	6.8	1/2	362.1	
22/09/2016	29/09/2016	315.38	229.14	933.14	850.31	7	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	115.45	
22/09/2016	29/09/2016	315.38	229.14	933.14	850.31	7	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	139.96	
22/09/2016	29/09/2016	315.38	229.14	933.14	850.31	7	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	148.23	
22/09/2016	6/10/2016	315.38	229.14	933.14	850.31	14	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	162.6	
22/09/2016	6/10/2016	315.38	229.14	933.14	850.31	14	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	158.92	
22/09/2016	6/10/2016	315.38	229.14	933.14	850.31	14	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	164.19	
26/09/2016	17/10/2016	315.38	229.14	933.14	850.31	21	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	187.81	
26/09/2016	17/10/2016	315.38	229.14	933.14	850.31	21	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	188.68	
26/09/2016	17/10/2016	315.38	229.14	933.14	850.31	21	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	196.97	
26/09/2016	24/10/2016	315.38	229.14	933.14	850.31	28	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	226.27	
26/09/2016	24/10/2016	315.38	229.14	933.14	850.31	28	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	219.94	
26/09/2016	24/10/2016	315.38	229.14	933.14	850.31	28	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	222.46	
26/09/2016	3/10/2016	332.31	239.53	909.35	828.63	7	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	115.45	
26/09/2016	3/10/2016	332.31	239.53	909.35	828.63	7	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	139.96	
26/09/2016	3/10/2016	332.31	239.53	909.35	828.63	7	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	148.23	
26/09/2016	10/10/2016	332.31	239.53	909.35	828.63	14	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	162.6	
26/09/2016	10/10/2016	332.31	239.53	909.35	828.63	14	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	158.92	
26/09/2016	10/10/2016	332.31	239.53	909.35	828.63	14	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	164.19	
27/09/2016	18/10/2016	332.31	239.53	909.35	828.63	21	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	187.81	
27/09/2016	18/10/2016	332.31	239.53	909.35	828.63	21	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	189.68	
27/09/2016	18/10/2016	332.31	239.53	909.35	828.63	21	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	196.97	
27/09/2016	25/10/2016	332.31	239.53	909.35	828.63	28	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	222.46	
27/09/2016	25/10/2016	332.31	239.53	909.35	828.63	28	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	219.94	
27/09/2016	25/10/2016	332.31	239.53	909.35	828.63	28	0	0	2850	3-4	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1389.67	1574.52	2669.51	0.86	0.33	3.09	3/4	222.46	
17/10/2016	24/10/2016	370	240.92	1093.6	584.66	7	3.15	0	2850	6-7	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1246.95	1368.47	2667.97	1.13	0.57	2.45	1/2	160.57	
17/10/2016	24/10/2016	370	240.92	1093.6	584.66	7	3.15	0	2850	6-7	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1246.95	1368.47	2667.97	1.13	0.57	2.45	1/2	156.57	
17/10/2016	24/10/2016	370	240.92	1093.6	584.66	7	3.15	0	2850	6-7	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1246.95	1368.47	2667.97	1.13	0.57	2.45	1/2	172.3	
17/10/2016	31/10/2016	370	240.92	1093.6	584.66	14	3.15	0	2850	6-7	0.00	1732	1912.82	2686.42	2.42	0.55	3.27	1246.95	1368.47	2667.97	1.13	0.57	2.45	1/2	175.45	
17/10/2016	31/10/2016	370	240.92	1093.6	584.66																					

INSTRUMENTO DE RECOLECCIÓN DE DATOS PARA EL INFORME FINAL DE TESIS "REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL CONCRETO DE CONSTRUCCIÓN A PARTIR DE SUS PARÁMETROS DE FABRICACIÓN EN LA CIUDAD DE ABANCAY-2024"

Nota: Ejemplo de recolección de datos de las tesis citadas

c) Recolección de datos ambientales de la ciudad de Abancay

Se incorporó las variables ambientales complementarias (Temperatura media °C) debido a que su incidencia es directa dentro del proceso de la hidratación del cemento y como consecuencia en el desarrollo de la resistencia mecánica del concreto. Estas variables se incluyeron debido a que nos permiten capturar los efectos ambientales de la ciudad de Abancay y mejorar la capacidad predictiva del modelo de red neuronal artificial.

Los valores de la temperatura media se obtuvieron a través de la plataforma Historical Weather API, que proporciona registros climáticos históricos verificados a partir de las diferentes estaciones meteorológicas locales.

Figura 10

Fuente meteorológica consultada



Nota: Figura tomada de la página Open Meteo- <https://open-meteo.com/en/docs>.

El proceso de recolección de esta información se realizó a través de coordenadas locales de los lugares donde se realizó el curado de las probetas de concreto, además de obtener la información de fechas para su respectivo seguimiento y control de las edades, como se detallará en la siguiente tabla:

Tabla 13

Registro de información

N°	REGISTRO DE INFORMACION	Lab. De ejecucion- curado	Coordenad as de lugar de curado	Fecha
1	REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL CONCRETO DE CONSTRUCCIÓN A PARTIR DE SUS PARÁMETROS DE FABRICACIÓN EN LA CIUDAD DE ABANCAY-2024	Laboratorio de Suelos, Concreto y Pavimentos Linux Ingenieros S.R.L	-13.633 -72.870	26/04/2025 al 3/06/2025
2	ESTUDIO COMPARATIVO EN LA AUTOCONSTRUCCIÓN DE EDIFICACIONES UTILIZANDO CONCRETO AUTOCOMPACTANTE CON LA INCORPORACIÓN DE ADITIVO SUPERPLASTIFICANTEFRETE AL CONCRETO CONVENCIONAL REALIZADOS EN LA CUIDAD DE ABANCAY	Laboratorio de suelos y concreto UTEA	-13.632 -72.887	22/09/2016 al 16/11/2016
3	ESTUDIO DEL DISEÑO DE MEZCLA CON CEMENTO TIPO HE Y DISEÑO DE MEZCLA CON ADITIVO Z FRAGUA # 5 PARA ACELERAR LA RESISTENCIA INICIAL A LA COMPRESIÓN DEL CONCRETO F'C = 210 KG/CM2	Laboratorio de Mecánica de Rocas y Suelos- UNAMBA	-13.6177 -72.8678	16/10/2021 al 19/11/2021
4	EFFECTOS DE LA ADICION DE FIBRA DE POLIESTER 40/2 EN LAS PROPIEDADES PLASTICAS Y MECANICAS EN COMPRESION AXIAL Y FLEXION CON DOSIFICACION OPTIMA DEL CONCRETO F'C 210 KG/CM2 ABANCAY APURIMAC 2019	Laboratorio GEOMAT SERV E.I.R.L.	-13.635 -72.890	1/02/2020 al 29/02/2020
5	INFLUENCIA DE LA SUSTITUCIÓN PARCIAL DEL CEMENTO POR CENIZA DE AGAVE AMERICANO EN	Laboratorio de suelos CONCHIPA E.I.R.L.	-13.63 -72.88	15/01/2022 al 12/02/2022

LAS PROPIEDADES MECÁNICAS DEL CONCRETO F'C =20.59 MPA, ABANCAY, APURÍMAC, 2020				
6	EVALUACIÓN DE LA RESISTENCIA A LA COMPRESIÓN Y FLEXOTRACCIÓN DEL CONCRETO ELABORADO CON CENIZA DE BAGAZO DE CAÑA DE AZÚCAR COMO SUSTITUTO PARCIAL DEL CEMENTO EN ABANCAY, 2019.	Laboratorio de suelos CONCHIPA E.I.R.L.	-13.63 -72.88	13/03/2020 al 10/04/2020
7	ANÁLISIS DE LA INFLUENCIA DE LA SUSTITUCIÓN PARCIAL DEL CEMENTO POR CENIZA DE RASTROJO DE ZEA MAYS L. EN LA RESISTENCIA MECÁNICA DE CONCRETO F'C=24.5 MPA, DISTRITO DE ABANCAY, PROVINCIA DE ABANCAY, REGIÓN APURÍMAC – 2020	Laboratorio GEOMAT SERV E.I.R.L.	-13.635 -72.890	5/09/2020 al 3/10/2020
8	INFLUENCIA DEL CURADO EN LA RESISTENCIA A LA COMPRESIÓN DEL CONCRETO PREPARADO CON CEMENTO PORTLAND TIPO I Y CEMENTO PUZOLÁNICO TIPO IP EN LA CIUDAD DE ABANCAY – APURIMAC	Laboratorio GEOLEF	-13.633 -72.883	9/05/2017 al 14/06/2017
9	INFLUENCIA DE LA ADICION DE FIBRAS SINTETICAS DE POLIPROPILENO EN LA RESISTENCIA AL AGRIETAMIENTO POR CONTRACCION PLASTICA Y LA RESISTENCIA A LA COMPRESION DEL CONCRETO F'C=210KG/CM2 EN LOSAS ALIGERADAS ABANCAY 2021	Laboratorio de suelos CONCHIPA E.I.R.L.	-13.63 -72.88	22/01/2022 al 19/02/2022
10	INFLUENCIA DE LAS PROPIEDADES MECANICAS DEL CONCRETO F'C=175 KG/CM2 CON LA INCORPORACION DE	Laboratorio de suelos y concreto Saywite S. A. C GEOLEF	-13.62 -72.87	15/08/2023 al 12/09/2023

PLASTICOS RECICLADOS (PET), ABANCAY, APURIMAC 2023				
11	DETERMINACION DE LA	Laboratorio de suelos	-13.63	18/08/2022
	RESISTENCIA A COMPRESION	CONCHIPA E.I.R.L.	-72.88	al
	AXIAL DEL CONCRETO			15/09/2022
	ESTRUCTURAL F'C=210KG/CM2			
	INTEGRADO A LA MEZCLA			
	COMO ADITIVO NATURAL EL			
	MUCILAGO DE PENCA DE TUNA			
	EN LA CIUDAD DE ABANCAY			
	2022			

Nota: Coordenadas locales de lugares de curado

Los datos obtenidos serán manejados bajo un instrumento de control donde se obtendrá el promedio de las fechas de control en base a las edades de las briquetas como se detallará en la siguiente tabla:

Figura 11

Modelo de instrumento de recolección de datos atmosféricos

 UNIVERSIDAD TECNOLÓGICA DE LOS ANDES Facultad de Ingeniería Ingeniería Civil			
PROYECTO: REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL CONCRETO DE CONSTRUCCIÓN A PARTIR DE SUS PARÁMETROS DE FABRICACIÓN EN LA CIUDAD DE ABANCAY - 2024 TESISTA: JANIO GINACIO PALOMINO VALENZUELA Ubicación de curado: Abancay, Laboratorio de Suelos, Concreto y Pavimentos Lunix Ingenieros S. R.L. FECHA: 26/04/2025 al 3/06/2025			
N°	Fecha de control	Temperatura _2m_ media (°C)	Humedad _Relativa_ _2m_ media (%)
1	2025-04-26T00:00	17	69
2	2025-04-27T00:00	16.2	80
3	2025-04-28T00:00	16.2	79
4	2025-04-29T00:00	16.8	83
5	2025-04-30T00:00	16.3	83
6	2025-05-01T00:00	16.1	83
7	2025-05-02T00:00	15.8	78
8	2025-05-03T00:00	15.7	80
9	2025-05-04T00:00	15.2	84
10	2025-05-05T00:00	15.7	84
11	2025-05-06T00:00	15.7	83
12	2025-05-07T00:00	15.4	80
13	2025-05-08T00:00	15.7	80
14	2025-05-09T00:00	16.4	72
15	2025-05-10T00:00	16.3	80
16	2025-05-11T00:00	15.2	83
17	2025-05-12T00:00	15.5	85
18	2025-05-13T00:00	15.5	79
19	2025-05-14T00:00	16.2	74
20	2025-05-15T00:00	16	74
21	2025-05-16T00:00	15.7	75
22	2025-05-17T00:00	16.6	70
23	2025-05-18T00:00	16.8	64
24	2025-05-19T00:00	16	76
25	2025-05-20T00:00	15.7	82
26	2025-05-21T00:00	15.9	82
27	2025-05-22T00:00	16	82
28	2025-05-23T00:00	15.9	84
29	2025-05-24T00:00	15.9	82
30	2025-05-25T00:00	15.7	84
31	2025-05-26T00:00	15	80
32	2025-05-27T00:00	15.8	74
33	2025-05-28T00:00	15	71
34	2025-05-29T00:00	14.4	79
35	2025-05-30T00:00	15	80
36	2025-05-31T00:00	15	72
37	2025-06-01T00:00	14.6	78
38	2025-06-02T00:00	14.7	72
39	2025-06-03T00:00	14.6	75
Promedio 7D		16.275	77.125
Promedio 14D		16.147	78.27
Promedio 28D-1er tanda		16.183	79.20
Promedio 28D-2er tanda		15.797	77.72
Promedio 28D-3er tanda		15.955	78.83
		Fecha: 1/05/2025 al 29/05/2025	
INSTRUMENTO DE RECOLECCIÓN DE DATOS PARA EL INFORME FINAL DE TESIS "REDES NEURONALES ARTIFICIALES PARA LA PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL CONCRETO DE CONSTRUCCIÓN A PARTIR DE SUS PARÁMETROS DE FABRICACIÓN EN LA CIUDAD DE ABANCAY 2024"			

Nota: Instrumento de recolección de características ambientales

Los datos fueron organizados en hojas de cálculo, verificando su consistencia con el uso de un análisis exploratorio. Bajo este método se pudo identificar registros incompletos, valores extremos y posibles errores de la digitación, con el fin de garantizar una fiabilidad y representatividad de la muestra.

d) Preparación y procesamiento de los datos para el modelo de RNA

Antes del entrenamiento del modelo de RNA, se aplicó un proceso riguroso de preprocesamiento y depuración sobre el conjunto de datos conformado por los 687 registros experimentales obtenidos. Esta etapa fue crítica para garantizar la calidad, coherencia y la

escalabilidad de los datos, elementos fundamentales que directamente inciden en la capacidad de aprendizaje, generalización y estabilidad del modelo predictivo.

1) Revisión exhaustiva de los datos (1X1) y Manejo de datos faltantes

Antes de aplicar cualquier técnica de automatizado, se realizó una revisión manual de los diferentes registros del dataset. En esta inspección minuciosa se nos permitió detectar errores sutiles que no son identificables como valores nulos (“NaN”), tales como:

- Valores imposibles.
- Inconsistencia en las unidades de medida o etiquetas.
- Registros de duplicados o mal estructurados.
- Imputación de datos faltantes usando random forest.

Aunque también se usaron herramientas automáticas, la revisión manual fue la clave para asegurar la calidad inicial del dataset.

Durante la revisión del dataset de 687 registros, se verifico que no existían valores faltantes en ninguna de las 17 variables de entrada luego de la aplicación y revisión sistemática de la base de datos completa, tampoco en la variable objetivo. Esto nos permitió evitar técnicas de imputación o eliminación de registros, lo cual representa una fortaleza metodología. Contar con un conjunto de datos completamente estructurado y sin omisiones, nos garantiza una base robusta para el posterior entrenamiento del modelo, además de reducir el riesgo de sesgo y facilitar una evaluación más confiable del desempeño predictivo de la RNA.

En resumen, el dataset fue depurado mediante: (a) eliminación de duplicados, (b) detección de outliers con boxplot y Z-score, (c) imputación de valores faltantes usando Random Forest y (d)

estandarización de unidades. Cada decisión metodológica fue registrada para asegurar trazabilidad del modelo durante el entrenamiento.

2) Detección y tratamiento de valores atípicos (Outliers)

Con el fin de garantizar que los valores extremos no distorsionen el proceso de aprendizaje del modelo, se aplicó un análisis específico sobre la variable objetivo (Resistencia a compresión del concreto), utilizando el método del rango intercuartílico (IQR), definido por la siguientes formulas:

$$IQR = Q_3 - Q_1$$

Donde:

$$\text{Límite inferior} = Q_1 - 1.5 * IQR$$

$$\text{Límite superior} = Q_3 + 1.5 * IQR$$

Donde Q_1 y Q_3 corresponden al primer y tercer cuartil de la distribución. Todos los registros con valores fuera de ese rango serán considerados potencialmente atípicos.

Además, el análisis aplicado nos mostró que ninguno de los valores de resistencias a compresión se ubicaba fuera del rango definido, por lo tanto, no fue necesario eliminar ni transformar ninguno de los registros en esta etapa. Esta validación se centró exclusivamente en la variable dependiente, esto debido a su impacto directo en la función de pérdida durante el proceso de entrenamiento, especialmente si se usa el error cuadrático medio (MSE y RMSE), que penaliza en gran medida a los errores grandes.

3) Normalización de las variables

El conjunto de las variables independientes incluía a datos con escalas muy diferentes, como contenido de cemento (kg/m^3), edad (días), proporciones como la relación de agua/cemento, entre otras. Esta disparidad de los parámetros puede afectar el proceso del entrenamiento de las RNA, ya que las variables con mayor magnitud tienden a dominar el cálculo de la gradiente, afectando de esta manera la convergencia del modelo.

Por este motivo, se aplicó la técnica de normalización de Min-Max, ya que transforma todos los valores de una variable al rango $[0,1]$ mediante la siguiente formula:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Mediante esta transformación se trabajó de manera independiente para cada variable del conjunto de entrenamiento, utilizando sus valores mínimos y máximos. Esto evito el problema conocido como data leakage, que ocurre cuando se usan datos del conjunto de prueba para calcular los parámetros estadísticos de entrenamiento, afectando la validez de la evaluación.

El resultado fue un conjunto de datos escalado uniformemente, lo que contribuyó a la estabilidad del algoritmo de retropropagacion, mejorar la velocidad de la convergencia y así asegurar que todas las demás variables aporten de forma equitativa al aprendizaje del modelo.

4) Selección de las características (Feature selection)

Durante el proceso de preparación del conjunto de los datos, se realizó la depuración selectiva de las variables no por criterios estadísticos de correlación, sino por criterios metodológicos relacionados con la consistencia del diseño experimental y la disponibilidad uniforme de los datos obtenidos.

Primero, se comenzó eliminando la variable como el % de la humedad relativa, dado que en todas las muestras utilizadas en el entrenamiento del modelo fueron curadas bajo condiciones estándares de laboratorio al 100% de humedad. Por lo tanto, esta variable no presentaba una variabilidad real alguna, lo que nos mostraría que esta variable es irrelevante para el modelo de aprendizaje automático.

Además, se excluyó la variable slump (asentamiento) esto principalmente debido a que la gran mayoría de los registros obtenidos de las tesis consultadas no contenían dicha medición, y su ausencia habría limitado el tamaño del conjunto de los datos disponibles para el posterior entrenamiento, esta variable es importante, se recomienda un seguimiento adecuado para modelos futuros con su implementación.

Para el caso de las variables como el peso específico de los agregados finos y grueso, su eliminación respondió al criterio de redundancia estructural. Como el modelo se construyó en base de los diseños de mezcla expresados en unidades de masa por metro cubico (cemento-kg, agua-L, agregado fino-kg, agregado grueso-kg), el peso específico de los agregados estaba implícitamente representado en los datos las dosificaciones volumétricas. Mantener estas variables habría introducido redundancia y multicolinealidad, sin aportar información adicional útil y posible incremento de ruido innecesario en el modelo de predicción.

Finalmente, la variable de densidad del concreto fue descartada por que solo estaba presente en los registros generados directamente por el autor, y su incorporación habría terminado reduciendo significativamente la cantidad de datos utilizables y comprometiendo la homogeneidad del dataset.

Estas decisiones fortalecieron la consistencia del modelo de RNA asegurando que todas las variables escogidas estuvieran disponibles de forma uniforme, además que estas fueran coherentes

con el esquema de la mezcla y representaran correctamente las condiciones locales del concreto que se produce en la ciudad de Abancay.

e) Flujograma de elaboración de la red neuronal artificial

Se hizo uso de un flujograma para probar RNA existentes en la web (github, kaggle, etc.), modelos ya elaborados y probados, pero estos modelos se enfocaban en predicciones generales, lo cual dificulta su incorporación para la predicción en nuestra ciudad de Abancay, es por eso por lo que se implementó una metodología para crear un nuevo modelo de RNA exclusivamente para el uso bajo las condiciones y características de nuestra ciudad de Abancay.

1. Importación de librerías

En esta etapa se establecen las librerías y semillas a usar para su posterior reproductibilidad.

Se importaron diferentes librerías, como tensorflow, keras, scikit-learn, numpy y pandas. Además, de fijarse una semilla aleatoria (42) para garantizar la reproductibilidad de los resultados del modelo.

2. Carga y exploración de datos

En esta etapa se procede a fijar la base de datos llamada “Tesis_D.csv” donde se imputaron los valores faltantes y su normalización

El código se encarga de realizar la carga de los datos desde el archivo “Tesis_D.csv”, seguido de un proceso de imputación de los valores omitidos durante la purificación de datos, esto se hará usando la normalización de las variables continuas con la técnica de Min-Mas scaling.

3. Preparación de datos

En esta etapa se realizó la organización del conjunto de datos antes de ser utilizada en la red neuronal artificial. Esto con el objetivo de asegurar que la información este limpia, completa y se encuentre en el formato adecuado para su posterior procesamiento. En este punto se revisan la información uno por uno para que se asegure de no tener valores faltantes, duplicados, inconsistentes o vacíos que puedan afectar al entrenamiento

4. Detección de outliers

En esta etapa se identifican los valores atípicos que se alejan significativamente del comportamiento de los datos. Estos valores pueden deberse a diferentes factores como errores de medición, digitación o condiciones experimentales y su presencia pueden afectar el correcto entrenamiento de los modelos generando predicciones inestables.

5. Escalado de las variables

En esta etapa se transforman los valores numéricos a un mismo rango de magnitud, esto se realiza con el fin de que todas las variables aporten de manera equitativa al proceso de aprendizaje. En esta investigación se aplicó la normalización tipo Min-Max, que ajusta los valores entre un intervalo de 0 y 1, conservando sus proporciones originales.

6. Selección de semilla para la reproducción del modelo

En esta etapa se fija un valor numérico que nos permitirá controlar la aleatoriedad de los procesos de muestreo y entrenamiento. Establecer una semilla fija y nos asegura que las divisiones de los datos tanto de entrenamiento como de prueba sean siempre las mismas además de fijar los pesos de la red, asegurando así su posterior reproductividad del modelo entrenado.

7. Construcción del modelo (arquitectura)

En esta etapa se define la estructura interna del modelo de RNA, es decir, la forma de cómo se organizarán las neuronas y la conexión entre ellas para procesar la información. La arquitectura del modelo permite que aprenda relaciones no lineales entre las variables, es por eso por lo que se requiere una arquitectura adecuada dependiendo del tipo de proyecto en el que se esté trabajando.

8. Entrenamiento del modelo

En esta etapa se lleva a cabo el proceso mediante el cual la RNA comienza a ajustar sus pesos internos, esto con el fin de minimizar los errores de predicción. Durante esta etapa, el modelo comienza a visualizar datos de entrenamiento y realizar múltiples iteraciones en las que compara su predicción con los valores reales y corrige los pesos utilizando el optimizador.

9. Revisión de la función de perdida

Durante esta etapa se analiza el comportamiento de los errores del modelo, esto errores que ocurrieron durante el proceso de entrenamiento. Este seguimiento nos permite verificar si la RNA está aprendiendo adecuadamente o también si presenta signos de inestabilidad o algún sobreajuste.

10. Evaluación del modelo

Durante esta etapa se mide cual fue el desempeño final de la RNA utilizando los datos de prueba, que no participaron en el entrenamiento. Esto lo hace con el objetivo de determinar que tanto generaliza el modelo su aprendizaje ante información nueva.

11. Verificación de no sobreajuste overfitting

Durante esta etapa se analiza si el modelo ha mantenido un equilibrio adecuado tanto en el aprendizaje como en la generalización. Este control es fundamental para que una RNA memorice los datos de entrenamiento y tenga la capacidad de predecir correctamente las muestras nuevas y no perder la capacidad a futuro.

12. Red neuronal artificial entrenada y verificada

En la etapa final se consolidan los resultados obtenidos tras todo el proceso de modelado. En este punto, nuestra RNA ya ha pasado por las diferentes fases de depuración, entrenamiento y validación, así demostrando un desempeño optimo y estable.


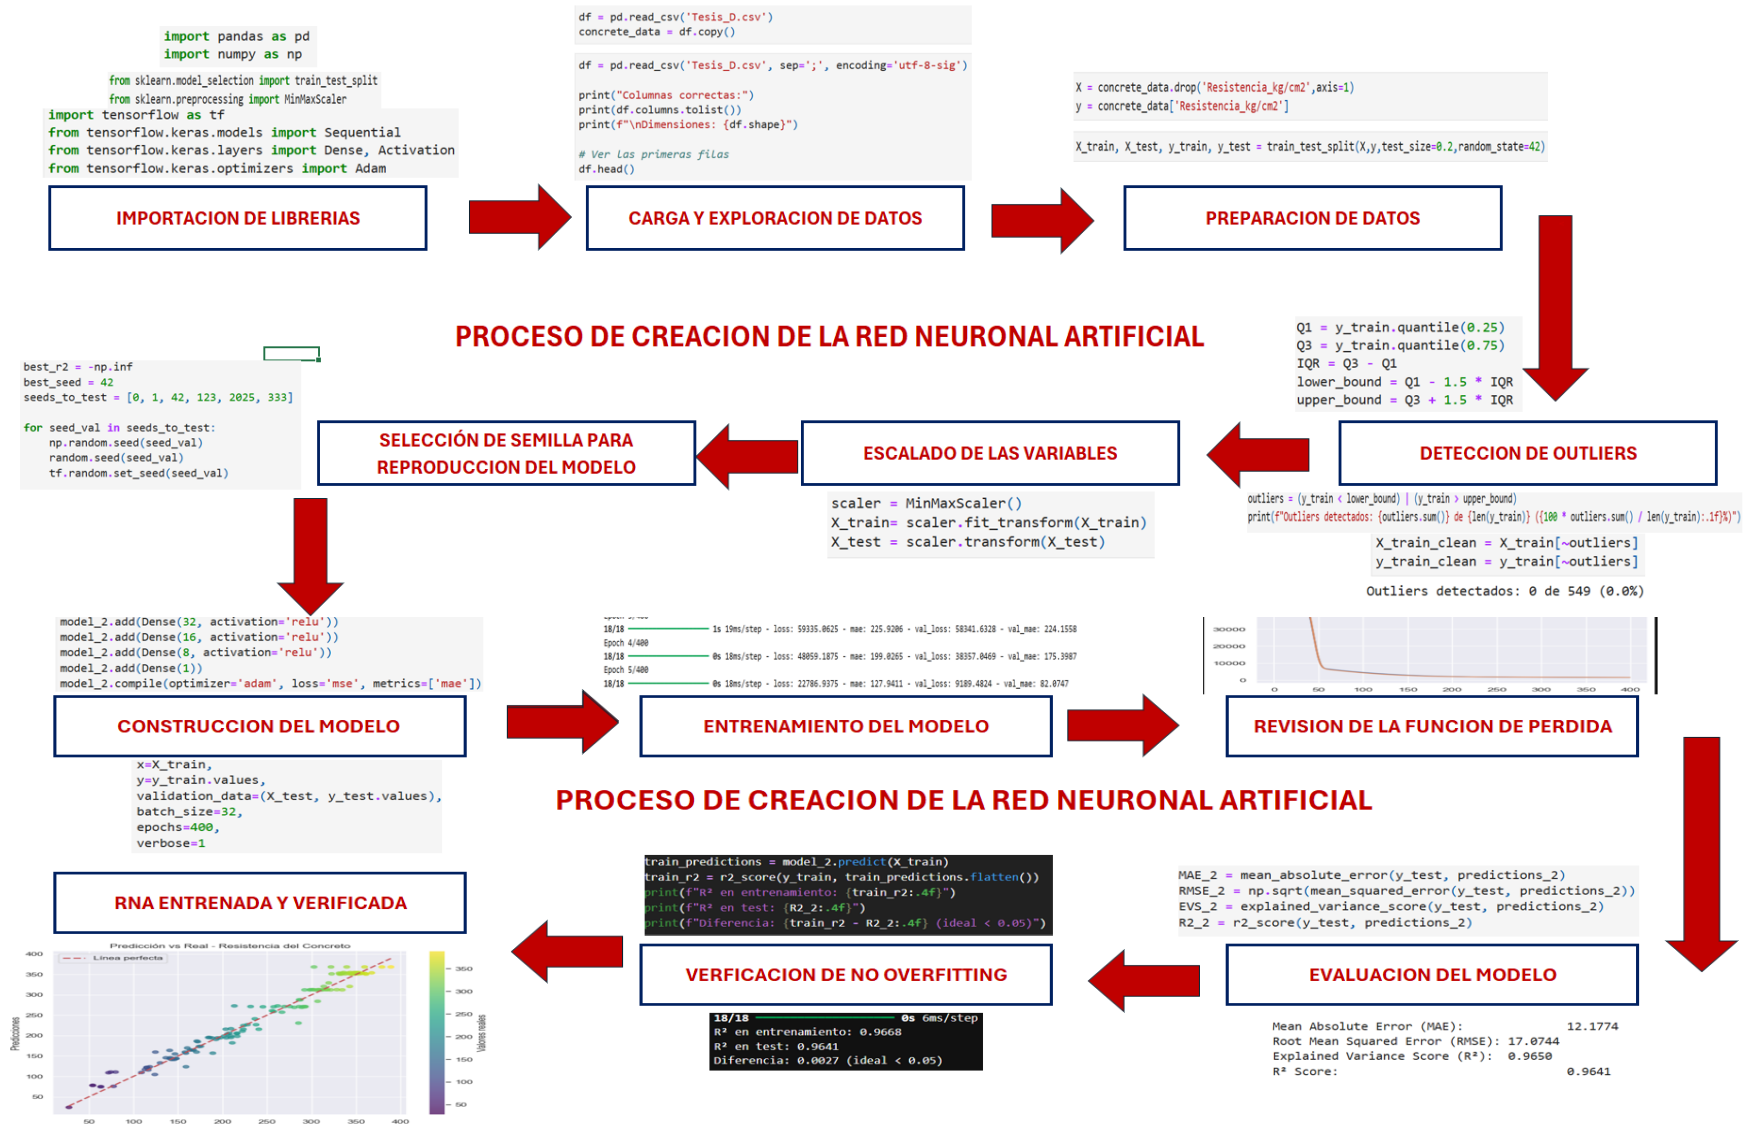


Figura 12

Flujograma de elaboración de la RNA



4.6 Análisis de datos

Levin & Rubín (2003) nos describe que los análisis de datos son técnicas estadísticas que nos ayudan a comprender e inferir sobre una muestra o población en base de un análisis de ella. En la presente investigación los datos serán procesados usando gráficos, tablas estadísticas en el software Python y Excel, el cual nos facilitara la comprensión de los resultados en base a nuestros objetivos planteados.

a) Obtención de resultados de briquetas de concreto

Resistencia a 7, 14 y 28 días

Tabla 14

Resultados de rotura a los 7 días

Nº	7 días		
	Resistencia kg/cm ²	X-U	$(X - U)^2$
1	294.31	-26.23	687.98
2	269.79	-1.71	2.92
3	261.81	6.27	39.28
4	285.58	-17.50	306.23
5	278.90	-10.82	117.05
6	270.68	-2.60	6.74
7	279.26	-11.18	124.90
8	280.83	-12.75	162.60
9	273.89	-5.81	33.72
10	288.27	-20.19	407.68
11	283.12	-15.04	226.25
12	284.18	-16.10	259.22
13	286.19	-18.11	327.92
14	264.54	3.54	12.53
15	254.56	13.52	182.87
16	249.09	18.98	360.43
17	250.77	17.31	299.57
18	257.28	10.80	116.69
19	266.05	2.03	4.11
20	276.29	-8.21	67.48
21	252.71	15.37	236.19

22	284.90	-16.82	283.01
23	255.55	12.53	157.01
24	259.65	8.43	71.12
25	235.40	32.68	1067.75
26	254.23	13.85	191.86
27	270.81	-2.73	7.45
28	243.19	24.89	619.27
29	253.47	14.61	213.49
30	239.18	28.90	835.44
31	279.12	-11.04	121.91
32	299.26	-31.18	972.18
33	251.63	16.45	270.53
34	264.74	3.34	11.15
35	284.99	-16.91	286.04
36	257.46	10.62	112.84
37	251.67	16.41	269.15
38	281.38	-13.30	176.79
39	283.46	-15.38	236.63
40	248.38	19.70	388.13
41	250.59	17.49	305.97
42	248.80	19.28	371.64
43	264.49	3.59	12.92
44	286.05	-17.97	322.86
45	303.73	-35.65	1270.75
46	271.45	-3.37	11.36

Nota: Representan los resultados obtenidos después de 7 días de curado

Tabla 15

Análisis estadístico de resultados a los 7 días

Σ	Suma	12331.66
N°	Muestras	46.00
X	Promedio	268.080
S^2	Varianza	12569.647
S	Desviación Estándar	16.71
V	Coeficiente de variación	6.23
Min	Valor mínimo	235.40
Max	Valor máximo	303.73
R	Diferencia V. Max-V. Min	68.32

Nota: Resultados para observar varianza a los 7 días

Tabla 16

Resultados de rotura a los 14 días

14 días			
N°	Resistencia kg/cm^2	X-U	$(X - U)^2$
1	312.44	-4.40	19.40
2	304.51	3.52	12.40
3	311.49	-3.46	11.94
4	309.52	-1.49	2.22
5	314.51	-6.47	41.87
6	337.84	-29.81	888.61
7	310.66	-2.62	6.87
8	326.64	-18.61	346.23
9	306.31	1.72	2.96
10	313.56	-5.53	30.53
11	310.73	-2.70	7.28
12	301.62	6.41	41.10
13	319.30	-11.27	126.96
14	312.27	-4.24	17.96
15	310.23	-2.20	4.83
16	316.79	-8.75	76.62
17	305.62	2.42	5.85
18	330.36	-22.33	498.51
19	317.01	-8.98	80.57
20	305.75	2.29	5.22
21	301.09	6.94	48.22
22	303.77	4.27	18.20
23	307.70	0.34	0.11
24	301.99	6.04	36.54
25	320.21	-12.18	148.23
26	305.87	2.17	4.69
27	292.96	15.08	227.27
28	311.18	-3.15	9.91
29	304.28	3.75	14.10
30	292.57	15.46	239.15
31	289.54	18.49	341.91
32	290.30	17.74	314.60
33	299.95	8.08	65.31
34	298.74	9.29	86.33
35	285.71	22.32	498.27
36	285.99	22.05	486.17
37	294.66	13.37	178.88
38	285.21	22.83	521.08
39	307.66	0.37	0.14
40	293.12	14.91	222.33
41	297.09	10.94	119.75
42	301.89	6.15	37.81

43	326.24	-18.20	331.36
44	305.53	2.51	6.30
45	328.20	-20.17	406.77
46	336.25	-28.22	796.24
47	325.16	-17.12	293.22
48	315.63	-7.60	57.70

Nota: Representan los resultados obtenidos después de 14 días de curado

Tabla 17

Análisis estadístico de resultados a los 14 días

Σ	Suma	14785.66
Nº	Muestras	48.00
X	Promedio	308.035
S^2	Varianza	7738.502
S	Desviación Estándar	12.83
V	Coeficiente de variación	4.17
Min	Valor mínimo	285.21
Max	Valor máximo	337.84
R	Diferencia V. Max-V. Min	52.64

Nota: Resultados para observar varianza a los 14 días

24	346.44	-1.30	1.69	72	354.47	-8.87	78.74	119	355.95	-9.49	90.04
25	341.02	4.12	16.98	73	329.59	16.01	256.29	120	327.04	19.42	377.16
26	348.14	-3.00	9.00	74	333.62	11.98	143.54	121	347.51	-1.05	1.10
27	346.35	-1.21	1.47	75	339.69	5.91	34.92	122	335.57	10.89	118.49
28	360.25	-15.10	228.16	76	348.45	-2.85	8.15	123	322.87	23.59	556.29
29	359.21	-14.07	198.00	77	347.31	-1.71	2.92	124	348.97	-2.51	6.32
30	332.17	12.98	168.37	78	335.44	10.16	103.29	125	352.15	-5.69	32.35
31	350.46	-5.31	28.23	79	333.51	12.09	146.16	126	344.37	2.09	4.37
32	339.75	5.39	29.08	80	325.64	19.97	398.62	127	345.27	1.19	1.41
33	347.40	-2.25	5.07	81	343.67	1.93	3.72	128	321.79	24.67	608.75
34	360.83	-15.69	246.23	82	336.49	9.11	83.00	129	360.22	-	189.37
										13.76	
35	372.90	-27.76	770.60	83	347.33	-1.73	3.00	130	332.11	14.35	206.01
36	372.84	-27.69	766.95	84	339.88	5.72	32.68	131	355.02	-8.56	73.28
37	337.89	7.25	52.54	85	334.24	11.37	129.17	132	354.31	-7.85	61.70
38	325.59	19.56	382.43	86	351.86	-6.26	39.17	133	351.39	-4.94	24.36
39	334.66	10.48	109.92	87	330.99	14.61	213.50	134	342.68	3.77	14.24
40	329.76	15.38	236.59	88	342.25	3.35	11.25	135	346.04	0.42	0.18
41	331.64	13.51	182.46	89	325.94	19.66	386.41	136	341.23	5.23	27.36
42	341.98	3.16	9.99	90	358.66	-13.06	170.51	137	342.57	3.89	15.11
43	328.01	17.13	293.53	91	366.87	-21.27	452.30	138	341.29	5.17	26.68
44	331.30	13.84	191.56	92	337.98	7.62	58.09	139	327.12	19.34	373.93
45	346.92	-1.77	3.14	93	363.64	-18.04	325.33				
46	350.35	-5.21	27.15	94	368.56	-22.96	526.99				
47	329.27	15.87	251.81	95	362.03	-16.42	269.78				
48	341.24	3.90	15.23								

Nota: Representan los resultados obtenidos después de 28 días de curado

Tabla 19 Análisis estadístico de resultados a los 28 días

Σ	Suma	48054.28
N°	Muestras	139.00
$\bar{X}$	Promedio	345.71
S^2	Varianza	21837.28

S	Desviación Estándar	12.58
V	Coeficiente de variación	3.64
Min	Valor mínimo	315.89
Max	Valor máximo	376.81
R	Diferencia V. Max-V. Min	60.92

Nota: Resultados para observar varianza a los 28 días

Tenemos coeficientes de variación entre los rangos de 3.63% a 6.23% los cuales se encuentran dentro de los rangos óptimos establecidos por el ACI 214, para el control de calidad de concreto en la investigación. Esta variabilidad natural de los datos es característica del comportamiento real del concreto y nos proporciona un conjunto de datos base robusto para el entrenamiento de nuestra red neuronal artificial.

Promedio según la ACI 318-19

Tabla 20

Promedio de probetas de concreto según ACI 318

PROMEDIO-ACI 318-19				
7 días	14 días	28 días	28 días	28 días
Resistencia	Resistencia	Resistencia	Resistencia	Resistencia
Promedio	Promedio	Promedio	Promedio	Promedio
kg/cm²	kg/cm²	kg/cm²	kg/cm²	kg/cm²
282.10	306.83	371.17	361.33	361.33
284.23	315.17	343.03	345.00	344.67
279.83	312.20	339.97	349.03	352.63
290.60	315.90	339.03	350.70	340.20
274.77	318.40	361.80	349.70	355.10
255.10	324.37	358.50	337.87	370.20
264.07	314.43	349.83	349.33	358.73
269.27	305.17	345.77	352.33	338.60
252.83	309.73	343.60	338.73	344.30
255.57	303.97	351.10	351.63	355.27
278.33	301.77	350.10	340.17	351.10
273.30	291.23	368.80	347.57	352.77
271.60	298.60	339.30	339.77	347.00
252.20	303.33	342.53	347.20	351.67
282.97	327.97	336.37	365.10	335.3
270.50	326.23	350.03	371.17	

Nota: Promedio de resistencias para uso y prueba de la RNA

Antes del entrenamiento se realizó un análisis exploratorio de los datos, con el fin de entender la naturaleza de las variables de entrada, además de observar posibles valores atípicos, analizar su distribución y explorar las relaciones preliminares con la resistencia a compresión. Esto

nos permitirá analizar la calidad de los datos y así poder fundamentar las decisiones posteriores como la normalización, el tratamiento de outliers y la selección de las variables.

b) Datos organizados y depurados

Una vez que se tiene identificadas las variables de entrada que se usaran en el desarrollo de la RNA, se procedió a la preparación y el procesamiento de los datos, con el fin de entrenar el modelo de RNA.

El conjunto de los datos recolectados de los ensayos experimentales fue ordenado y clasificado, las variables independientes seleccionadas y preparados para la lectura correspondiente en archivo Tesis_D.csv:

Tabla 21
Descripción variables de entrada de estudio de la RNA

Variable	Descripción	Unidad
R_a/c	Relación agua cemento del diseño de mezcla	N/A
Cemento_kg	Cantidad de cemento en la mezcla medida en $1m^3$	kg
Agua_L	Cantidad de agua en la mezcla medida en $1m^3$	Litros
Ag_Grueso_kg	Cantidad de agregado grueso en la mezcla medida en $1m^3$	kg
Ag_fino_kg	Cantidad de agregado grueso en la mezcla medida en $1m^3$	kg

Edad_dias	Edad de rotura de las briquetas de concreto	días
Superplastificante_kg	Cantidad de superplastificante en la mezcla medida en $1m^3$	kg
Aditivo_Acelerante_kg	Cantidad de Aditivo acelerante en la mezcla medida en $1m^3$	kg
Den_Cemento_kg/m3	Densidad de diseño de mezcla según el método ACI 211	kg/cm^3
Temp_prom_C	Temperatura promedio media calculada del promedio de días de la probeta en curado	°C
Ag_fino_Porcentaje_absorcion_%	Porcentaje de absorción del agregado fino muestra tomada de diferentes canteras de Abancay	%
Ag_fino_Contenido_Humedad_%	Contenido de humedad del agregado fino muestra tomada de diferentes canteras de Abancay	%
Ag_fino_Modulo_fineza	Módulo de fineza del agregado fino muestra tomada de diferentes canteras de Abancay	N/A
Ag_grueso_Porcentaje_absorcion_%	Porcentaje de absorción del agregado grueso muestra tomada	%

	de diferentes canteras de	
	Abancay	
Ag_grueso_Contenido_Humedad_%	Contenido de humedad del	%
	agregado grueso muestra tomada	
	de diferentes canteras de	
	Abancay	
Ag_grueso_Modulo_fineza	Módulo de fineza del agregado	N/A
	grueso muestra tomada de	
	diferentes canteras de Abancay	
Ag_grueso_TMN_mm	Tamaño máximo nominal del	mm
	agregado grueso muestra tomada	
	de diferentes canteras de	
	Abancay	

Nota: Contenido y descripción de las variables de la RNA

Donde tendremos a variable dependiente:

Tabla 22

Descripción de variable de salida

Variable	Descripción	Unidad
Resistencia_kg/cm2	Resistencia a la compresión del	kg/cm^2
	concreto elaborado en la ciudad	
	de Abancay	

Nota: Resultado que se busca obtener con la RNA

Previo al entrenamiento, los datos fueron depurados y normalizados, esto con el fin de evitar posibles errores durante el entrenamiento, además de asegurar una coherencia y comparabilidad entre las variables. Se eliminaron registros de valores faltantes, valores atípicos, inconsistencias y se aplicó la normalización Min-Max, que transforma los valores de las variables dentro del rango [0-1], con esto se evita que las variables con magnitudes mayores puedan dominar el proceso de aprendizaje.

La depuración outliers ya se había realizado previa recolección de datos, pero para asegurar la veracidad, se agregó el código por si obviamos algún error.

El conjunto de los datos obtenidos se dividió aleatoriamente 80% para entrenamiento y 20% para testeo, teniendo un total de 549 datos de entrenamiento y 138 datos para testeo o validación, recordando que los datos de validación son para verificar y probar el modelo entrenado.

Todo el procedimiento se realizó utilizando el entorno de Python, usando las bibliotecas como pandas, numpy y scikit-learn. Además, se aseguró la reproductibilidad del modelo, fijando semillas aleatorias.

Tabla 23
Formato final de base de datos para el entrenamiento de la RNA

R_a/c	Cemento_kg	Agua_L	Ag_fino_kg	Ag_Grueso_kg	Edad_dias	Superplastificante_kg	Aditivo Acelerante_kg	Den_Cemento_kg/cm3	Temp_prom_°C	Ag_fino_Porcentaje_absorcion_%	Ag_fino_Contenido_Humedad_%	Ag_fino_Modulo_fineza	Ag_grueso_Porcentaje_absorcion_%	Ag_grueso_Contenido_Humedad_%	Ag_grueso_Modulo_fineza	Ag_grueso_tamaño_max_”	Resistencia_kg/cm2
0.65	370	240.92	1093.6	584.66	7	3.15	0	2850	16.975	2.42	0.55	3.27	1.13	0.57	2.45	12.70	160.57
0.65	370	240.92	1093.6	584.66	7	3.15	0	2850	16.975	2.42	0.55	3.27	1.13	0.57	2.45	12.70	164.52
0.65	370	240.92	1093.6	584.66	7	3.15	0	2850	16.975	2.42	0.55	3.27	1.13	0.57	2.45	12.70	172.3
0.65	370	240.92	1093.6	584.66	14	3.15	0	2850	16.627	2.42	0.55	3.27	1.13	0.57	2.45	12.70	175.15
0.65	370	240.92	1093.6	584.66	14	3.15	0	2850	16.627	2.42	0.55	3.27	1.13	0.57	2.45	12.70	195.21
0.65	370	240.92	1093.6	584.66	14	3.15	0	2850	16.627	2.42	0.55	3.27	1.13	0.57	2.45	12.70	195.98
0.65	370	240.92	1093.6	584.66	21	3.15	0	2850	16.691	2.42	0.55	3.27	1.13	0.57	2.45	12.70	199.55
0.65	370	240.92	1093.6	584.66	21	3.15	0	2850	16.691	2.42	0.55	3.27	1.13	0.57	2.45	12.70	205.71
0.65	370	240.92	1093.6	584.66	21	3.15	0	2850	16.691	2.42	0.55	3.27	1.13	0.57	2.45	12.70	202.26
0.65	370	240.92	1093.6	584.66	28	3.15	0	2850	17.000	2.42	0.55	3.27	1.13	0.57	2.45	12.70	215.33
0.65	370	240.92	1093.6	584.66	28	3.15	0	2850	17.000	2.42	0.55	3.27	1.13	0.57	2.45	12.70	212.1
0.65	370	240.92	1093.6	584.66	28	3.15	0	2850	17.000	2.42	0.55	3.27	1.13	0.57	2.45	12.70	217.96
0.65	370	240.04	1091.58	583.86	7	4.16	0	2850	16.625	2.42	0.55	3.27	1.13	0.57	2.45	12.70	168.68
0.65	370	240.04	1091.58	583.86	7	4.16	0	2850	16.625	2.42	0.55	3.27	1.13	0.57	2.45	12.70	161.88
0.65	370	240.04	1091.58	583.86	7	4.16	0	2850	16.625	2.42	0.55	3.27	1.13	0.57	2.45	12.70	166.98
0.65	370	240.04	1091.58	583.86	14	4.16	0	2850	16.793	2.42	0.55	3.27	1.13	0.57	2.45	12.70	185.79
0.65	370	240.04	1091.58	583.86	14	4.16	0	2850	16.793	2.42	0.55	3.27	1.13	0.57	2.45	12.70	195.05
0.65	370	240.04	1091.58	583.86	14	4.16	0	2850	16.793	2.42	0.55	3.27	1.13	0.57	2.45	12.70	187.43
0.65	370	240.04	1091.58	583.86	21	4.16	0	2850	16.664	2.42	0.55	3.27	1.13	0.57	2.45	12.70	206.18
0.65	370	240.04	1091.58	583.86	21	4.16	0	2850	16.664	2.42	0.55	3.27	1.13	0.57	2.45	12.70	207
0.65	370	240.04	1091.58	583.86	21	4.16	0	2850	16.664	2.42	0.55	3.27	1.13	0.57	2.45	12.70	203.77
0.65	370	240.04	1091.58	583.86	28	4.16	0	2850	16.993	2.42	0.55	3.27	1.13	0.57	2.45	12.70	223.28
0.65	370	240.04	1091.58	583.86	28	4.16	0	2850	16.993	2.42	0.55	3.27	1.13	0.57	2.45	12.70	219.23
0.65	370	240.04	1091.58	583.86	28	4.16	0	2850	16.993	2.42	0.55	3.27	1.13	0.57	2.45	12.70	223.56
0.65	370	239.16	1090.09	583.07	7	5.18	0	2850	16.650	2.42	0.55	3.27	1.13	0.57	2.45	12.70	171.26
0.65	370	239.16	1090.09	583.07	7	5.18	0	2850	16.650	2.42	0.55	3.27	1.13	0.57	2.45	12.70	190.45
0.65	370	239.16	1090.09	583.07	7	5.18	0	2850	16.650	2.42	0.55	3.27	1.13	0.57	2.45	12.70	186.99
0.65	370	239.16	1090.09	583.07	14	5.18	0	2850	16.680	2.42	0.55	3.27	1.13	0.57	2.45	12.70	216.32
0.65	370	239.16	1090.09	583.07	14	5.18	0	2850	16.680	2.42	0.55	3.27	1.13	0.57	2.45	12.70	216.21
0.65	370	239.16	1090.09	583.07	14	5.18	0	2850	16.680	2.42	0.55	3.27	1.13	0.57	2.45	12.70	207.77
0.65	370	239.16	1090.09	583.07	21	5.18	0	2850	16.777	2.42	0.55	3.27	1.13	0.57	2.45	12.70	225.97
0.65	370	239.16	1090.09	583.07	21	5.18	0	2850	16.777	2.42	0.55	3.27	1.13	0.57	2.45	12.70	230.35
0.65	370	239.16	1090.09	583.07	21	5.18	0	2850	16.777	2.42	0.55	3.27	1.13	0.57	2.45	12.70	223.67
0.65	370	239.16	1090.09	583.07	28	5.18	0	2850	16.645	2.42	0.55	3.27	1.13	0.57	2.45	12.70	240.44
0.65	370	239.16	1090.09	583.07	28	5.18	0	2850	16.645	2.42	0.55	3.27	1.13	0.57	2.45	12.70	262.92
0.65	370	239.16	1090.09	583.07	28	5.18	0	2850	16.645	2.42	0.55	3.27	1.13	0.57	2.45	12.70	247.35
0.52	393.87	205.86	937.66	823.89	1	0	0	2960	17.05	4.07	4.74	3.23	0.85	1.36	4.66	12.70	59.56
0.52	393.87	205.86	937.66	823.89	1	0	0	2960	17.05	4.07	4.74	3.23	0.85	1.36	4.66	12.70	63.69
0.52	393.87	205.86	937.66	823.89	1	0	0	2960	17.05	4.07	4.74	3.23	0.85	1.36	4.66	12.70	56.55
0.52	393.87	205.86	937.66	823.89	1	0	0	2960	17.05	4.07	4.74	3.23	0.85	1.36	4.66	12.70	63.27
0.52	393.87	205.86	937.66	823.89	1	0	0	2960	17.05	4.07	4.74	3.23	0.85	1.36	4.66	12.70	62.98
0.52	393.87	205.86	937.66	823.89	1	0	0	2960	17.05	4.07	4.74	3.23	0.85	1.36	4.66	12.70	64.69
0.52	393.87	205.86	937.66	823.89	2	0	0	2960	16.83	4.07	4.74	3.23	0.85	1.36	4.66	12.70	120.11
0.52	393.87	205.86	937.66	823.89	2	0	0	2960	16.83	4.07	4.74	3.23	0.85	1.36	4.66	12.70	122.07
0.52	393.87	205.86	937.66	823.89	2	0	0	2960	16.83	4.07	4.74	3.23	0.85	1.36	4.66	12.70	122.41
0.52	393.87	205.86	937.66	823.89	2	0	0	2960	16.83	4.07	4.74	3.23	0.85	1.36	4.66	12.70	116.76
0.52	393.87	205.86	937.66	823.89	2	0	0	2960	16.83	4.07	4.74	3.23	0.85	1.36	4.66	12.70	113.03
0.52	393.87	205.86	937.66	823.89	2	0	0	2960	16.83	4.07	4.74	3.23	0.85	1.36	4.66	12.70	123.95
0.52	393.87	205.86	937.66	823.89	3	0	0	2960	18.7	4.07	4.74	3.23	0.85	1.36	4.66	12.70	157.66
0.52	393.87	205.86	937.66	823.89	3	0	0	2960	18.7	4.07	4.74	3.23	0.85	1.36	4.66	12.70	166.74
0.52	393.87	205.86	937.66	823.89	3	0	0	2960	18.7	4.07	4.74	3.23	0.85	1.36	4.66	12.70	141.91
0.52	393.87	205.86	937.66	823.89	3	0	0	2960	18.7	4.07	4.74	3.23	0.85	1.36	4.66	12.70	162.13
0.52	393.87	205.86	937.66	823.89	3	0	0	2960	18.7	4.07	4.74	3.23	0.85	1.36	4.66	12.70	166.40

Nota: Ejemplo del modelo final de base de datos

Tabla 24
Análisis estadístico de toda la base de datos


Variable	Media	Mediana	Moda	Desviación Estándar	Skew (Asimetría)
Relacion agua/cemento	0.54	0.52	0.52	0.05	2.40
Cemento_kg	385.50	393.87	393.87	23.94	-1.34
Agua_L	206.49	205.86	208.00	12.96	-0.02
Agregado_fino_kg	929.93	955.67	975.00	84.15	-0.91
Agregado_Grueso_kg	875.20	889.00	823.89	106.48	-0.25
Edad_dias	15.16	14.00	28.00	10.16	0.18
Superplastificante_kg	0.22	0.00	0.00	0.95	4.29
Aditivo_Acelerante_kg	2.36	0.00	0.00	5.87	2.08
Densidad_Cemento_kg/cm3	3055.69	3150.00	3150.00	124.05	-0.77
Temperatura_promedio_C	16.72	16.65	16.15	0.74	0.62
Agregado_fino_Porcentaje_absorcion_%	2.64	1.83	4.07	1.15	0.35
Agregado_fino_Contenido_Humedad_%	4.00	4.40	4.74	1.41	-1.20
Agregado_fino_Modulo_fineza	3.13	3.14	3.23	0.14	0.62
Agregado_grueso_Porcentaje_absorcion_%	1.36	1.08	0.85	1.19	2.48
Agregado_grueso_Contenido_Humedad_%	0.91	1.02	1.36	0.76	0.56
Agregado_grueso_Modulo_fineza	5.62	6.60	4.66	1.47	-0.52
Agregado_grueso_tamaño maximo mm	15.15	12.70	12.70	4.69	1.55
Resistencia kg/cm2	237.14	240.80	334.50	90.65	-0.30

Nota: Análisis estadístico final de la base de datos a entrenar

Figura 13

Curva de porcentaje de crecimiento del concreto de tesis consultadas

PORCENTAJE DE DESARROLLO DE RESISTENCIA - COMPARATIVA DE TESIS CONSULTADAS



Nota: Grafico elaborado por el autor de la curva de porcentaje de crecimiento.

Según Montgomery y Runger (2021) quienes indican que la inspección visual de la distribución de los datos mediante histogramas es indispensable y esencial para validar los supuestos de normalidad y la homogeneidad de la varianza, principalmente cuando se usan métodos paramétricos como la correlación de Pearson.

Con el fin de analizar el comportamiento estadístico de las variables experimentales escogidas y verificar la coherencia de la base de datos obtenida, se procedió a realizar un análisis descriptivo mediante histogramas, gráficos de dispersión, y diagrama de Cajas (Box plots). Estos gráficos nos ayudaran a visualizar la distribución de las frecuencias, identificar los posibles valores atípicos que se haya recolectado y reconocer el tipo de asimetría presente en las variables escogidas.

La representación gráfica se elaboró usando el entorno de Python, usando biblioteca como matplotlib, este análisis visual nos ayudará a complementar la estadística descriptiva de nuestra base de datos y nos permitirá validar la consistencia de los datos antes realizar el modelado predictivo.

El diagrama de dispersión nos sirve para poder entender las relaciones lineales entre las variables independientes y la variable dependiente, particularmente entre las variables más predominantes como la relación agua/cemento, cemento, agua etc. lo que sugiere una coherencia en el proceso de mezclado.

Mientras que los diagramas de cajas o boxplots nos permite observar la dispersión de los diferentes datos y de esta forma poder identificar la presencia de posibles valores atípicos. Para nuestra investigación fue indispensable analizar los valores atípicos, debido a la heterogeneidad de los datos obtenidos.

Figura 14

Histograma de distribución de los datos recopilados vs resistencia




Figura 15

Gráficos de dispersión de datos de Cemento, agua, agregado fino, agregado grueso y temperatura




Figura 16

Graficó de boxplot, Cemento, agua, agregado fino, agregado grueso y temperatura.





Figura 17


Histograma de distribución de la resistencia a compresión del concreto



Nota: Elaboración de grafico de Histograma de distribución de la resistencia a compresión propia

Figura 18

Boxplot de la resistencia a compresión del concreto



Nota: Grafico elaborado por el autor de los bloxplots

c) Identificar relaciones entre variables mediante la matriz de correlación

Con el fin de obtener los parámetros de fabricación del concreto que más inciden en el crecimiento de la resistencia a compresión del concreto, se utilizó el análisis de correlación de Pearson. Con este procedimiento se puede medir el grado de asociación lineal entre las diferentes variables independientes de la mezcla, así como de la resistencia obtenida a los diferentes días de ensayo.

Se tuvo que recurrir a la literatura y ajuste de muchas de las variables en uso, debido a que el modelo de RNA, adquiriría demasiado ruido al incluir demasiadas variables que terminaban limitando su correcto funcionamiento, es por eso por lo que se trabajó solo con 17 variables de entrada, eliminando variables para conveniencia de la investigación.

El cálculo de la matriz se realizó en Python, empleando las diferentes bibliotecas disponibles como pandas, numpy y seaborn para poder visualizar los diferentes coeficientes en un mapa de calor conocido como heatmap.


La interpretación de la matriz de correlación se hará de la siguiente manera:

Tabla 25
Valores de correlación de Pearson

Valor	Fuerza Correlación	Significado
± 0.9 a ± 1.0	Muy fuerte	Relación casi perfecta
± 0.7 a ± 0.9	Fuerte	Relación importante
± 0.5 a ± 0.7	Moderada	Relación considerable
± 0.3 a ± 0.5	Débil	Relación baja

± 0.0 a ± 0.3	Muy débil	Prácticamente no hay relación
-----------------------	-----------	-------------------------------

Nota: Valores de correlación de Pearson para validar los agregados

Figura 19*Matriz de correlación de Pearson elaborado en Python***Matriz de Correlación - Variables del Concreto**

Nota: Grafico de matriz de correlación elaborado por el autor.

Se eliminaron variables como el slump, densidad de la muestra de concreto, pesos específicos de los agregados, etc. Debido a que, durante la recolección de datos, no se pudo obtener valores específicos de slump solo redondeados o modificados a criterio del autor, lo mismo con la densidad que no se calculaba en la mayoría de los casos y así con las demás variables que no se incorporaron en la matriz de correlación.

Se puede observar que las variables que muestran mayor influencia directa son la edad del concreto y las propiedades específicas de los agregados, mientras que otros como los aditivos nos muestran relaciones complejas no lineales ya que actúan como facilitadores sinérgicos esto lo hacen modificando la influencia sobre las demás variables. La relación a/c pese a su importancia fundamental nos muestra una correlación moderada con la resistencia, se presentará el motivo por el cual la relación a/c no muestra mayor influencia, esto se explicará más adelante. Mientras que las variables ambientales como la temperatura nos muestran correlaciones complejas no lineales, con valores óptimos. Gracias a la matriz de correlación se puede justificar como el empleo de modelos de RNA nos permite capturar las interacciones no lineales entre las variables, algo que los métodos tradicionales tienden a obviar.

4.7 Consideraciones técnicas

La presente investigación se desarrolló bajo los principios de integridad científica, objetividad y transparencia. Todos los datos utilizados fueron elaborados por ensayos experimentales y las fuentes académicas fueron verificados por expertos en la materia, datos que fueron procesados sin manipulación ni alteración de resultados.

Los datos experimentales consultados fueron obtenidos siguiendo el proceso de transparencia y uso con fines netamente académicos siguiendo la norma universitaria de ética.

Durante el tratamiento de la información secundaria, consultada de las diferentes tesis y documentos institucionales, se respetaron los derechos de autor y se garantizó la correcta cita a los autores conforme a la norma APA 7 edición.

La elaboración y entrenamiento del modelo de RNA se elaboró siguiendo guías específicas, asegurando de esta manera la trazabilidad de los datos y su posterior reproductibilidad de los procedimientos computacionales, evitando cualquier practica que implique sesgo o distorsión deliberada de los resultados.

Finalmente, la investigación se rige bajo las normas éticas y reglamentos internos de investigación de la Universidad tecnológica de los Andes, promoviendo el uso responsable de la tecnología y su difusión transparente del conocimiento.

V. Resultados y discusión

- Diseño de modelo de red neuronal artificial

Se implemento un modelo de red neuronal artificial con el propósito de predecir la resistencia a compresión del concreto elaborado en la ciudad de Abancay esto a partir de sus parámetros de fabricación locales, se incluyeron las propiedades de los materiales, diseño de mezcla y las condiciones ambientales. Este enfoque se plantea en búsqueda de superar las limitaciones de los métodos empíricos tradicionales al capturar las relaciones no lineales y sinérgicas inherentes al comportamiento del concreto.

a) Tipo de modelo

Se implemento un modelo correspondiente a una RNA de tipo Perceptron multicapa (MLP), con una arquitectura feedforward con aprendizaje supervisado, este tipo de modelos son de amplio uso para la predicción de las propiedades del concreto por su capacidad de modelar las relaciones no lineales complejas.

b) Variables de entrada y salida

El modelo que se empleó consiste en 17 variables predictoras estas relacionadas con los parámetros de fabricación del concreto en la ciudad de Abancay y una variable objetivo. A continuación, se presenta la tabla 28:

Tabla 26

Variables de entrada y salida de la RNA

Tipo	Nombre de la variable	Descripción	Unidad
Entrada	Cemento_kg	Cantidad de cemento	kg/m ³
Entrada	Agua_L	Cantidad de agua	L/m ³
Entrada	Ag_fino_kg	Cantidad de agregado fino	kg/m ³
Entrada	Ag_Grueso_kg	Cantidad de agregado grueso	kg/m ³

Entrada	Edad_dias	Edad del concreto	días
Entrada	Superplastificante_kg	Cantidad de superplastificante	kg/m ³
Entrada	Aditivo_Acelerante_kg	Cantidad de aditivo acelerante	kg/m ³
Entrada	Den_Cemento_kg/cm3	Densidad del cemento	kg/m ³
Entrada	Temp_prom_C	Temperatura promedio durante curado	°C
Entrada	Ag_fino_Porcentaje_absorcion_%	Absorción del agregado fino	%
Entrada	Ag_fino_Contenido_Humedad_%	Humedad del agregado fino	%
Entrada	Ag_fino_Modulo_fineza	Módulo de finura del agregado fino	—
Entrada	Ag_grueso_Porcentaje_absorcion_%	Absorción del agregado grueso	%
Entrada	Ag_grueso_Contenido_Humedad_%	Humedad del agregado grueso	%
Entrada	Ag_grueso_Modulo_fineza	Módulo de finura del agregado grueso	—
Entrada	Ag_grueso_TMN_mm	Tamaño máximo nominal del agregado grueso	mm
Salida	Resistencia_kg/cm2	Resistencia a compresión del concreto	kg/cm ²

Nota: Procesamiento propio de variables

c) Arquitectura de la RNA

La arquitectura final del modelo consiste en una red MLP con tres capas ocultas, las cuales contienen las siguientes neuronas por capa: 200 → 150 → 100. Todas las capas ocultas utilizan la función de activación ReLU, mientras la capa final es lineal, adecuada para tareas de regresión continua.

Para obtener este modelo de arquitectura se entrenó varios modelos probando aleatoriamente con el fin de encontrar una arquitectura adecuada y usar ese modelo como base para establecer la arquitectura de RNA final.

Tabla 27

Examen aleatorio de arquitecturas de prueba


N° de iteraciones	Capas ocultas	MAE	RMSE	R2
1	2	129.685	150.07	-1.772
2	8	128.216	148.418	-1.711
3	2-2	62.287	72.88	0.346
4	8	62.063	72.786	0.348

5	8-4	32.527	45.427	0.746
6	8	71.529	82.719	0.158
7	2	240.278	256.629	-7.106
8	8-4	43.844	55.164	0.625
9	2-2	61.883	72.727	0.349
10	4-2	240.278	256.629	-7.106
11	4-2	40.64	52.136	0.665
12	2-2	240.279	256.63	-7.106
13	4	81.608	95.933	-0.133
14	2-2	240.278	256.629	-7.106
15	2-2	240.278	256.629	-7.106
16	64-44-30	22.282	30.957	0.882
17	64-38-22-15	17.369	23.968	0.929
18	64-44-22-15	21.035	28.998	0.897
19	64-44-22	21.432	29.521	0.893
20	64-38-19	22.522	30.669	0.884
21	32-19-9-5	23.207	31.594	0.877
22	32-22-15	24.306	32.943	0.866
23	64-44-26	22.804	31.234	0.88
24	32-19-11	27.34	36.373	0.837
25	32-19-11-5	26.606	35.667	0.843
26	32-19-11-6-4	25.468	34.148	0.856
27	64-44-26-18	24.604	33.294	0.864
28	32-16-8	24.726	34.073	0.857
29	64-32-19-9	18.017	24.918	0.924
30	16-8-5	27.284	37.847	0.824
31	16-8-5	29.104	40.473	0.798
32	16-11-7	28.422	37.965	0.823
33	16-11-7-4-4	29.44	40.844	0.795
34	32-22-13	26.797	35.807	0.842
35	64-32-19	22.78	31.209	0.88
36	256-204-142-85	16.872	22.653	0.937
37	128-102-81-48-38-22	15.576	21.03	0.946
38	128-102-61-36-25-20	14.679	20.091	0.95
39	128-102-81-48-38-30	16.301	21.869	0.941
40	128-76-60-48-38	18.505	24.971	0.923
41	64-44-26-20	21.001	28.465	0.9
42	64-51-40-24-14-11	20.863	28.653	0.899
43	256-179-125-87-52-36	17.218	22.195	0.939
44	64-44-30-21	21.347	28.704	0.899
45	128-102-61-48-33-19	20.804	27.711	0.905
46	64-51-35-21	18.395	24.746	0.925
47	64-51-40-28	19.478	26.609	0.913
48	64-44-26-15-12-8	20.745	29.012	0.896

49	256-179-107-64-44-26	16.957	22.398	0.938
50	128-102-71-56-33	15.785	21.399	0.944

Nota: Procesamiento propio de arquitecturas

Figura 20
Valores R^2 de arquitecturas probadas



Nota: Grafico producido por el autor de los Valores R^2 de arquitecturas probadas

Aquí se observa que en la iteración N° 38 con una arquitectura de 128 → 102 → 61 → 36
→ 25 → 20 nos da resultados óptimos:

Tabla 28
RNA con mejores resultados

N° Iteraciones	Capas ocultas	MAE	RMSE	R2
38	128-102-61-36-25- 20	14.679	20.091	0.95

Nota: Procesamiento propio de arquitecturas

Pero la arquitectura que nos muestra es compleja con muchas capas ocultas, pudiendo estar sujeta algún sesgo o variación durante su entrenamiento, además de tener un coste computacional demasiado alto.

Es por eso por lo que se optó por una RNA más simple con una arquitectura mucho menos compleja, también se puede observar que las iteraciones 17 y 29 muestran resultados prometedores con arquitecturas menos complejas, $64 \rightarrow 44 \rightarrow 22$ y $64 \rightarrow 32 \rightarrow 19 \rightarrow 9$ respectivamente:

Tabla 29

Arquitecturas menos complejas con mejores resultados

N° Iteraciones	Capas ocultas	MAE	RMSE	R2
17	64-38-22-15	17.369	23.968	0.929
29	64-32-19-9	18.017	24.918	0.924

Nota: Procesamiento propio de arquitecturas

Lo que nos indica que el modelo puede trabajar con arquitecturas más simples, y no tan complejas como la arquitectura que mostro mejor resultado.

También se aumentaron las iteraciones tomando de ejemplo este modelo como base:

Tabla 30

Arquitecturas con mayores iteraciones

N° de iteraciones	Capas ocultas	MAE	RMSE	R2
400	8-8-8-8	28.5637	39.3212	0.8115
400	64-32-32-16-8	17.0064	23.0551	0.9346

Nota: Procesamiento propio de arquitecturas

Donde la arquitectura de $64 \rightarrow 32 \rightarrow 32 \rightarrow 16 \rightarrow 8$ muestra un resultado prometedor, es por eso por lo que se decide mejorar esta arquitectura para obtener mejores resultados.

Tabla 31

Arquitectura final con aplicación de técnicas de regulación

Aplicación	N° de iteraciones	Capas ocultas	MAE	RMSE	R2
Dropout-30%-20%	400	64-32-32-16-8	30.454	35.1383	0.848
Earlystopping 30%-20%	400	64-32-32-16-8	25.5259	0.338898	0.8586

Nota: Procesamiento propio de arquitecturas

Durante el diseño del modelo final, también se evaluó la inclusión de técnicas de regularización como del dropout y el early stopping. Sin embargo, se obtuvo resultados que redujeron el coeficiente de determinación R^2 , sin la evidencia previa de un sobreajuste en el modelo final de RNA. Esto se debe en general a que nuestros datos son de calidad, con bajo ruido y coeficiente de variación dentro de los límites recomendados por el ACI 214, por este motivo se decidió mantener la arquitectura sin regularización, priorizando la capacidad predictiva de nuestro modelo final con una arquitectura de $64 \rightarrow 32 \rightarrow 32 \rightarrow 16 \rightarrow 8$, 17 variables de entrada con 3 capas ocultas de 64,32,32,16,8 y 1 capa de salida.

d) Procesamiento de datos

Los datos fueron normalizados mediante la técnica de Min-Max scaling, lo cual nos permitió transformar las variables al rango de [0,1]. La base de datos finales de 687 registros, que fueron divididos en 80% para el entrenamiento (549 muestras) y 20% para prueba (138 muestras). Además, para garantizar la reproductividad, se fijó la semilla aleatoria en 333 para numpy, Python y Tensorflow.

Para el caso de la semilla se probaron aleatoriamente 6 tipos de semillas:

Tabla 32

Semillas probadas en la RNA

Semilla	0	1	42	123	333	2025
R^2	0.9443	0.9643	0.9131	0.9342	0.9659	0.9177

Nota: Procesamiento propio de semillas para RNA sin k-fold

Donde se puede observar que la semilla que mostro mejor resultado fue 333, con la cual se ajustara el modelo para su posterior reproductividad.

- Aplicación de k-fold

Para aplicar k fold se debe tener en cuenta que:

Las RNA son muy sensibles a la inicialización aleatoria de sus pesos y a su posterior división de datos, es por eso por lo que se aplica k-fold para proporcionar una estimación más estable del rendimiento, así evitando el sesgo que nos puede dar una simple división de train/test.

Para evitar el sesgo por la partición de datos y mejorar la estimación del rendimiento real del modelo, se aplicó la técnica de validación cruzada k-fold con $k = 5$. Esta técnica consiste en dividir el conjunto de entrenamiento en cinco subconjuntos o “folds”, entrenando el modelo cinco veces, cada vez con un fold distinto como conjunto de validación y los cuatro restantes como entrenamiento. Posteriormente, se promediaron los resultados de las métricas (R^2 , RMSE, MAE) para obtener una estimación robusta del desempeño del modelo y su capacidad de generalización.

Esto lo haremos bajo la optimización de hiperparametros:

- 1) Se hará bajo la comparación de arquitecturas de RNA de manera adecuada.
- 2) Nos ayudara a encontrar una mejor combinación de:
 - a. Numero de capas y neuronas
 - b. Tasa de aprendizaje
 - c. Función de activación
 - d. Regularización

Las arquitecturas por usar serán:

Tabla 33
Arquitecturas con k-fold

TIPO	K-FOLD	
	ARQUITECTURA	EPOCAS
RED SIMPLE	100	350
RED OPTIMIZADA	150	1029
RED PROFUNDA	200-100	253
RED BALANCEADA	150-75	783

RED MUY PROFUNDA	200-150-100	326
RED PIRAMIDAL	100-75-50	296
RED ULTRA PROFUNDA	300-200-100-50	274
RED ENTRENADA	64-32-32-16-8	400

Nota: Arquitecturas escogidas para aplicación de k-fold

Se aplicará un k-fold = 5 para cada una de las arquitecturas, y se mantendrá el seed+ fold para el entrenamiento de cada una de ellas:

Se obtuvieron los siguientes resultados de cada una de las arquitecturas ensayadas:

Tabla 34
Resultados de k-fold en las arquitecturas probadas

TIPO	ARQUITECTURA	K-FOLD		
		R2-MEAN	RMSE MEAN	MAE MEAN
RED SIMPLE	100	0.8241 ± 0.0362	37.6926 ± 4.2578	27.4067 ± 3.0547
RED OPTIMIZADA	150	0.8986 ± 0.0105	28.7414 ± 1.5760	20.6237 ± 1.7141
RED PROFUNDA	200-100	0.8815 ± 0.0145	31.0509 ± 2.1932	22.4538 ± 2.0894
RED BALANCEADA	150-75	0.9210 ± 0.0455	24.5138 ± 7.0361	18.2154 ± 5.5255
RED MUY PROFUNDA	200-150-100	0.9460 ± 0.0121	20.8808 ± 2.4601	15.3824 ± 2.3036
RED PIRAMIDAL	100-75-50	0.9162 ± 0.0300	5.7613 ± 5.0508	19.2181 ± 3.7006
RED ULTRA PROFUNDA	300-200-100-50	0.9557 ± 0.0077	18.9579 ± 1.8295	13.9526 ± 1.0426
RED ENTRENADA	64-32-32-16-8	0.9278 ± 0.0194	24.0698 ± 3.4210	17.5771 ± 2.4036

Nota: k-fold propio de cuadro comparativo


Tabla 35
Resultados finales de aplicar k-fold

K-FOLD							
TIPO	ARQUITECTURA	R2-MEAN	R2_STD	RMSE-MEAN	RMSE-STD	MAE-MEAN	MAE-STD
RED SIMPLE	100	0.824	0.036	37.693	4.258	27..4067	3.055
RED OPTIMIZADA	150	0.899	0.0105	28.7414	1.576	20.624	1.714
RED PROFUNDA	200-100	0.882	0.0145	31.0509	2.193	22.454	2.089
RED BALANCEADA	150-75	0.921	0.0455	245138	7.036	18.215	5.526
RED MUJY PROFUNDA	200-150-100	0.95	0.0121	20.881	2.46	15.382	2.304
RED PIRAMIDAL	100-75-50	0.916	0.2996	25.7613	5.051	19.218	3.7
RED ULTRA PROFUNDA	300-200-100-50	0.956	0.0076	18.958	1.829	13.953	1.043
RED ENTRENADA	64-32-32-16-8	0.928	0.0194	24.0698	3.421	17.577	2.404

Nota: Elaboración de comparativa de k fold propia

Figura 21


Comparación de resultado obtenido por K-fold




Nota: Elaboración de comparativa entre las arquitecturas propia

Figura 22

Comparación final de coeficiente de determinación- R^2 con k -fold por cada arquitectura



Nota: Elaboración de gráficos de comparación propia

Figura 23*Arquitectura final de RNA*

Conexiones grises: TODAS las neuronas conectadas entre capas | Conexiones verdes: Bias conectado a TODAS las neuronas de su capa

Nota: Figura elaborada por el autor de la arquitectura final de la RNA

Se probó las 3 mejores RNA del modelo presentado, basándonos en el análisis comparativo de ellas, donde se observó un patrón prometedor revelándonos que las 3 arquitecturas muestran un rendimiento excelente, obteniendo valores de R^2 por encima de 0.94, lo que nos demuestra la capacidad para capturar los patrones complejos en los datos. Sin embargo, las diferencias entre ellas nos indican un delicado balance entre la complejidad y la eficacia de cada una de ellas.

La red muy profunda emerge como claramente superior, no solo por tener un mejor R^2 , sino también por que combina este alto rendimiento con una excepcional capacidad de generalización, mostrándonos la mínima diferencia entre sus resultados de validación cruzada y test. Esto nos puede indicar que su arquitectura de 200-150-100 neuronas representa el punto óptimo para este tipo de problemas específicos, donde las capas progresivamente más pequeñas logran sintetizar mejor la información sin la necesidad de crear cuellos de botella que puedan sacrificar el rendimiento de la RNA.

En caso de la red ultra profunda es demasiado curioso, ya que nos demuestra el principio de rendimientos decrecientes en la práctica: a pesar de tener un 45% más de neuronas y una cuarta capa adicional, su performance en el Test es inferior. Esto nos indica que la complejidad adicional no solo no mejora los resultados, sino que también puede estar perjudicándolo, probablemente por la última capa de 50 neuronas que actúa como filtro agresivo para la eliminación de información indispensable. Mientras que la Red final escogida como ejemplo, aunque demostró eficiencia en términos de número de parámetros, paga el precio de un rendimiento consistente más bajo, sugiriendo que su capacidad de modelado es insuficiente para la complejidad del problema que se está planteando.

Tabla 36

Comparación final de las mejores 3 arquitecturas

TIPO	ARQUITECTURA	R2-TEST	RMSE-TEST	MAE-TEST
RED MUY PROFUNDA	200-150-100	0.960268	17.605	13.942
RED ULTRA PROFUNDA	300-200-100-50	0.950001	19.749	15.7565
RED ENTRENADA	64-32-32-16-8	0.94153	21.3571	17.104

Nota: Elaboración de Comparación final propia

Luego de evaluar múltiples configuraciones de redes neuronales multicapa, se seleccionaron las tres mejores arquitecturas con rendimientos adecuados según los resultados de validación cruzada (k-fold) y las métricas R^2 , RMSE y MAE. Entre estas, la arquitectura 200–150–100, demostró ser la más adecuada para el presente estudio.

Esta arquitectura alcanzó un coeficiente de determinación R^2 de 0.9602, un error cuadrático medio (RMSE) de 17.60 kg/cm² y un error absoluto medio (MAE) de 13.94 kg/cm², superando en precisión a las arquitecturas más profundas como la RNA-ultra profunda (300–200–100–50) y a versiones más livianas como la red entrenada con 64–32–32–16–8.

La elección se fundamenta en un equilibrio entre desempeño predictivo y eficiencia computacional, ya que la arquitectura 200–150–100 logra una alta precisión sin incurrir en sobreajuste ni requerir tiempos de entrenamiento excesivos. Además, su profundidad permite capturar relaciones no lineales complejas entre los parámetros de fabricación del concreto y su resistencia, lo cual es coherente con la naturaleza multivariable del problema abordado.

e) Entrenamiento

El modelo final escogido se entrenó utilizando las librerías de TensorFlow/Keras durante 326 épocas, con un tamaño de lote (Batch size) de 32 y el optimizador Adam (tasa de aprendizaje)

que ya viene predeterminado en los modelos (0.001). La función de pérdida fue el error cuadrático medio (MSE), y se monitoreo el error absoluto medio (MAE) incluido como una métrica auxiliar. Como se indicó en el anterior párrafo, no se aplicó el earlystopping, pero se verifico la ausencia de sobreajuste a través de la comparación de la métrica R^2 tanto en el entramiento como la prueba.

f) Evaluación del modelo

El desempeño del modelo se evaluó utilizando el conjunto de prueba mediante las métricas de coeficiente de determinación (R^2), raíz del error cuadrático medio (RMSE) y el error absoluto medio (MAE).

Los resultados obtenidos con la RNA final fueron:

Tabla 37
Resultado final de la RNA

Categorías	N° de iteraciones	Capas ocultas	MAE	RMSE	R2
Train	326	200-150-100	13.10	17.48	0.9632
Test	326	200-150-100	13.94	17.61	0.9603

Nota: Procesamiento propio de RNA

Tabla 38
Error de predicción

Error promedio	13.94 kg/cm ²
Error típico	±17.61 kg/cm ²

Nota: Elaboración de error propia

El modelo explica 96.6% de la variabilidad en la resistencia

g) Verificación de no overfitting


Tabla 39

Verificación de no overfitting

R ² del modelo	Valor
R ² _train	0.9632
R ² _test	0.9603

Nota: Elaboración propia de verificación

Aquí se muestra que la RNA no se está presentando overfitting, dado que ambos valores son muy cercanos entre sí y no existe una diferencia significativa que nos pueda indicar que memoriza los datos de entrenamiento. Un modelo sobreajustado mostraría un (R^2) notablemente mayor en el entrenamiento y una caída considerable en los datos de prueba. Para este caso, la diferencia es mínima (0.0029) lo que nos puede indicar que la RNA tiene una excelente capacidad de generalización, reproduciendo adecuadamente las relaciones entre las variables y manteniendo un desempeño estable cuando se evalúa datos no utilizados durante su entrenamiento.

Figura 24*Métricas de entrenamiento y validación del modelo*

Nota: Grafico elaborado por el autor de la curva de función de perdida

La figura 24 nos indica que el modelo de RNA ha convergido de forma óptima, aprendiendo rápidamente y generalizando con éxito. La pérdida en el entrenamiento y su validación disminuyen drásticamente al inicio y se estabiliza en un valor muy bajo y prácticamente idéntico, lo que nos indica la ausencia de sobreajuste y una excelente capacidad para la predicción de datos no visto. Este es un comportamiento ideal para el entrenamiento, que refleja un modelo bien ajustado.

A continuación, se presenta la descripción general del modelo de RNA, junto con sus métricas globales de desempeño obtenidas durante el proceso de entrenamiento y testeo.

a) Descripción general del modelo de RNA

Modelo de RNA:

- Tipo = Perceptrón multicapa
- Arquitectura: $18 \rightarrow 200 \rightarrow 150 \rightarrow 100 \rightarrow 1$, 17 variables de entrada con 3 capas ocultas de 200,150,100 y 1 capa de salida.
- Datos = 687 registros
- Entrenamiento (train) = 80% de la muestra total (n=549)
- Prueba (test) = 20% de la muestra total (n=138)
- Numero de iteraciones = 326 épocas
- Optimizador = Adam
- Función de pérdida = Mean Absolute Error (MAE)
- Valores normalizados = Min-Max
- K-fold = 5

b) Evaluación del modelo de RNA

- MAE = 13.94kg/ cm²
- RMSE = 17.605kg/ cm²
- R² prueba = 0.9603
- R² entrenamiento = 0.9632

El valor del MAE equivale al 5% del valor medio de la resistencia observada, lo cual nos demuestra un margen de error aceptable dentro de los criterios de control de calidad. De igual manera el RMSE refleja una dispersión moderada de errores, lo que respalda la consistencia del modelo. Además, se tiene R² con una diferencia mínima, evitando así cualquier sobreajuste en el modelo, validando el modelo para pruebas.

Tabla 40

Métrica global de desempeño del modelo de RNA

RED MUY PROFUNDA			
TIPO	k-fold CV	TRAIN (549)	TEST (138)
R2	0.964	0.963268	0.9603
RMSE (Kg/cm2)	20.88	17.48	17.61
MAE (Kg/cm2)	15.38	13.1	13.94

Nota: Elaboración de métricas propia

Los valores obtenidos confirman que el modelo representa una adecuada capacidad para generalizar, manteniendo así un equilibrio entre la precisión y la estabilidad. A partir de estos resultados, en los apartados siguientes se analizará los gráficos detallados del comportamiento del modelo, evaluando la dispersión de los valores predichos, los residuales y sus métricas específicas por grupos.

- Métricas globales de desempeño del modelo RNA

Para la evaluación del modelo de RNA, se calcularon las métricas globales de ajuste y error donde se empleó el conjunto de datos obteniendo estos resultados:

Tabla 41
Métricas globales del desempeño de la RNA

Indicador	Símbolo	Valor	Interpretación
Número de muestras	N	687	Total, de observaciones empleadas
Media real	$\bar{y}_{\text{real}}$	237.14 kg/cm ²	Promedio experimental de resistencias
Media predicha	$\bar{y}_{\text{pred}}$	242.65 kg/cm ²	Promedio estimado por la RNA
Desviación estándar (real)	SD _{rea}	90.65 kg/cm ²	Variabilidad experimental
Desviación estándar (predicha)	SD _{pred}	90.15 kg/cm ²	Variabilidad estimada (ligeramente menor)
Error medio absoluto	MAE	13.1 kg/cm ²	Error promedio entre valores reales y predichos
Raíz del error cuadrático medio	RMSE	17.48 kg/cm ²	Dispersión global de los errores
Sesgo medio	ME	+5.51 kg/cm ²	Ligera sobreestimación global
Coefficiente de determinación	R^2	0.963	Alto poder explicativo (96.2 % de varianza explicada)
Correlación	r	≈ 0.983	Asociación lineal muy fuerte

Nota: Elaboración de métricas propia

Los resultados indican que el modelo presenta un alto nivel de ajuste global ($R^2 = 0.963$) y un error promedio bajo (MAE=13.1 kg/cm²), lo que confirma su precisión en la predicción de la


resistencia a la compresión del concreto. La media predicha con un valor de 242.65 kg/cm^2 es prácticamente cercana a la media real 237.14 kg/cm^2 , mostrándonos una ausencia del sesgo sistemático.

El sesgo medio positivo ($+5.51 \text{ kg/cm}^2$) nos indica una ligera sobreestimación del modelo, aunque esto puede ser insignificante frente a un rango total de resistencia. Además, se tiene una desviación estándar predicha de 90.15 kg/cm^2 comparándola con los 90.65 kg/cm^2 de la real nos indica una leve subdispersion, es decir, el modelo tiende a generar predicción ligeramente más comprimidas alrededor del valor medio de la muestra.

Figura 25

Grafica de crecimiento del concreto predicho por la RNA

ESTIMACION DE RESISTENCIA A COMPRESION CON APLICACION DE RNA - COMPARATIVA DE TESIS CONSULTADAS



Nota: Grafico elaborada por el autor de la curva de comparación de resistencia a compresión predicha por la RNA


c) Análisis de gráficos de ajusté del modelo

Con el fin de entender el desempeño del modelo y así verificar su coherencia entre los valores predichos y los valores reales de la resistencia, se ha realizado distintos análisis gráficos. Estas representaciones nos permitirán identificar la precisión del modelo, su comportamiento ante los errores y la posible existencia de sesgos sistemáticos en las predicciones.

- Curva de paridad de banda $\pm 10\%$, $\pm 20\%$ y $\pm 30\%$ (Predicho vs Real)

Figura 26

Curva de paridad del modelo



Nota: Grafico de curva de paridad elaborado por el autor

La figura 26 representa la curva de paridad correspondiente al conjunto de prueba, donde se comparan los valores de la resistencia a compresión predicho por el modelo (eje y) frente a los

valores reales obtenidos (experimentales y recopilados-eje x). la línea diagonal representa el ajuste perfecto ($y=x$), mientras que las líneas rojas delimitan la banda de tolerancia de $\pm 10\%$, $\pm 20\%$ y $\pm 30\%$ con respecto de la diagonal.

Por lo tanto, se puede inferir que la mayoría de los puntos se concentran cerca de la línea de igualdad y dentro de la banda de $\pm 10\%$, especialmente dentro del rango comprendido entre 200 y 350 kg/cm², lo que nos indica una alta correspondencia entre los valores reales y los predichos. Este comportamiento nos confirma la capacidad del modelo para reproducir la precisión de la resistencia promedio del concreto en los rasgos donde se dispone mayor densidad de datos experimentales.


Sin embargo, el modelo comienza a tener errores de sobreestimación en el sector de resistencias menos a 150 kg/cm², donde los puntos tienden a ubicarse por encima de la línea $y = x$. Por el contrario, en rangos de resistencia superiores a 350 kg/cm², se presenta una subestimación notoria con la mayoría de los puntos situados por debajo de la diagonal. Esto nos indica que el modelo ajusta mejor en valores intermedios, mientras que en los extremos converge con sesgos, esto puede deberse a la falta de información dentro de estos rangos.

Este comportamiento es coherente con el patrón esperado en los modelos predictivos basados en datos experimentales, principalmente si se usan materiales heterogéneos, en los cuales las dispersiones tienden a incrementarse en rangos de resistencia elevada debido a la mayor variabilidad asociada a los diferentes diseños de mezcla.

- Análisis de residuales y tendencias (LOWESS)

Figura 27

Análisis residuales y tendencias



Nota: Grafico de residuales y tendencia propia

En la figura 27 se muestra el grafico de residuales en función de los valores reales de la resistencia. En este caso, el residual se define como la diferencia entre el valor predicho y el valor real ($\text{residual} = y_{\text{pred}} - y_{\text{real}}$). Como se muestra en la nube de puntos, se colocó una curva de tendencia suavizada mediante el método lowess, con el fin de identificar posibles sesgos o patrones no lineales en el comportamiento de los errores.


El análisis de la curva nos indica un patrón de forma S. en el rango de resistencia menores a 150 kg/cm², los residuales se ubican mayormente en valores positivos, lo que indica que el modelo tiene a sobreestimar las posibles resistencias más bajas. En el intervalo comprendido entre 200 y 320 kg/cm², los residuales se concentran alrededor de cero, evidenciando una mejor calibración y un ajuste equilibrado entre los diferentes valores tanto predichos y como los

observados. Finalmente, por encima de 350 kg/cm². Los residuales adoptan valores negativos, lo que nos implica una subestimación de las resistencias más altas por parte del modelo.

Este comportamiento nos sugiere una ligera dependencia del error con respecto al nivel de la resistencia, puede ser atribuible a la menos cantidad de datos disponibles en los extremos rangos o a la influencia de factores no considerados en las variables de entrada. Sin embargo, la dispersión de los residuales se mantiene moderada y simétrica alrededor del eje cero, lo que nos indica ausencia de un sesgo sistemático global y esto respalda la estabilidad del modelo en la mayoría del dominio de predicción, confirmando que el modelo presenta un ajuste robusto y coherente con el comportamiento físico del concreto a diferentes rangos de resistencia.

Figura 28

Boxplots de residuales por banda de resistencia




Nota: Grafico de residuales por banda de resistencia propia.

En la figura 28 se muestran los boxplots residuales agrupados por bandas de resistencia, definidos por los intervalos de <150 , $150-200$, $200-300$ y >350 kg/cm². Cada diagrama nos muestra la mediana, los cuartiles y la dispersión total de los errores para cada grupo, lo cual nos permite evaluar su tendencia y variabilidad del modelo en distintos rangos de resistencia.

El análisis nos muestra las diferencias claras en el comportamiento de errores según la magnitud de la resistencia. En las bandas inferiores (<150 y $150-200$ kg/cm²), las medianas de los residuales son positivas, lo que nos indica una tendencia del modelo a sobreestimar las resistencias bajas. Este patrón coincide con el comportamiento detectado en la curva de LOWESS, donde los valores reales más pequeños representan residuales positivos.

En el rango $200-300$ kg/cm², las medianas se ubican muy cerca de cero, mostrándonos una calibración adecuada y un ajuste equilibrado entre los valores predichos y reales. Este es el intervalo donde el modelo exhibe una mayor estabilidad, esto debido a que concentra la mayor densidad de observaciones y la menor dispersión de errores.

Finalmente, en la banda superior (>350 kg/cm²), se observa una mediana negativa pronunciada, señal de la subestimación en las resistencias más altas. Esta tendencia puede atribuirse a la escasez de datos en dicho rango y a la mayor variabilidad del material en condiciones de alta resistencia, esto debido a las pequeñas diferencias en la dosificación o el curado generan variaciones significativas en los resultados experimentales.

Figura 29*Boxplots de residuales por edad*

Nota: Grafico de residuales por edad propia


La Figura 29 muestra los *boxplots* de los residuales agrupados según la edad del concreto al momento del ensayo (1, 2, 3, 4, 5, 7, 14, 21 y 28 días). El análisis evidencia que el comportamiento del error varía con el tiempo de curado, mostrando una tendencia general a la reducción de la dispersión conforme va aumentando la edad del concreto.

Al día 1, los residuales presentan una alta dispersión y una tendencia a la sobreestimación, lo cual resulta lógico considerando la mayor incertidumbre de las resistencias tempranas y la sensibilidad del material a pequeñas variaciones en el proceso de fraguado. Entre 2 y 5 días, el error disminuye notablemente, con medianas cercanas a cero y una distribución más compacta, lo que indica una mejor calibración y estabilidad del modelo en este periodo intermedio.


En las edades de 7 y 14 días, se observa una ligera asimetría en los resultados; en particular, las muestras de 7 días no dan una dispersión algo mayor que los de 28 días, aunque sin valores atípicos extremos. A los 21 y 28 días, los residuales se concentran estrechamente alrededor del eje cero, con medianas muy próximas a la línea de equilibrio, lo que demuestra que el modelo mantiene una precisión consistente en resistencias maduras.

Figura 30

Influencia de cada variable en el modelo predictivo SHAP



Fuente: Elaboración Propia de Figura

Figura 31*Evaluación de parámetros de entrada por SHAP*

Fuente: Elaboración de SHAP propia

Las Figuras 31 y 31 presenta el análisis de interpretabilidad mediante SHAP (SHapley Additive exPlanations) aplicado al modelo de Red Neuronal Artificial desarrollado para la predicción de la resistencia a compresión del concreto. Los resultados nos permiten identificar la contribución relativa de cada variable de entrada sobre las predicciones realizadas por el modelo, proporcionando una comprensión detallada de los factores que controlan el comportamiento predictivo de la red neuronal.

Los resultados muestran que la variable con mayor influencia sobre la resistencia predicha es la edad del concreto (Edad_dias), presentando el mayor valor medio absoluto de SHAP. Este comportamiento es consistente con los principios de la tecnología del concreto, ya que el desarrollo de la resistencia está directamente asociado al avance de las reacciones de hidratación del cemento. El gráfico SHAP evidencia además que valores elevados de edad generan contribuciones positivas sobre la resistencia predicha, mientras que edades tempranas producen efectos negativos, reflejando adecuadamente el comportamiento físico esperado del material.

La segunda variable más influyente corresponde al tamaño máximo nominal del agregado grueso (Ag_grueso_TMN_mm). El análisis de dispersión SHAP indica que valores elevados de esta variable tienden a reducir la resistencia estimada, mientras que tamaños menores generan contribuciones positivas. Este resultado puede atribuirse a la influencia del tamaño de agregado sobre la zona de transición interfacial y la distribución de esfuerzos dentro de la matriz cementicia, aspectos ampliamente reconocidos en la literatura especializada.

La densidad del cemento (Den_Cemento_kg/m³) aparece como la tercera variable de mayor relevancia. Los valores altos de esta variable muestran una contribución positiva sobre la resistencia predicha, sugiriendo que el modelo identifica una relación favorable entre mayores densidades y el desarrollo resistente. Este comportamiento podría estar asociado a variaciones en las características físicas del cemento o a diferencias en la dosificación efectiva de la mezcla.

Asimismo, las variables relacionadas con las propiedades del agregado grueso, como su contenido de humedad, porcentaje de absorción y cantidad incorporada en la mezcla, presentan una influencia significativa sobre las predicciones. Esto indica que el modelo reconoce la importancia del estado de humedad de los agregados en la determinación del agua efectiva

disponible para la hidratación, afectando indirectamente la relación agua-cemento y, por consiguiente, la resistencia final del concreto.

Aunque el contenido de cemento presenta un rango de variación amplio (312.3–558.8 kg/m³), la importancia SHAP obtenida fue relativamente baja. Este comportamiento puede atribuirse a la distribución no uniforme de los datos, concentrados principalmente entre 380 y 400 kg/m³, así como a la influencia simultánea de otras variables de mezcla y de la edad de ensayo. En consecuencia, el modelo identifica que las diferencias observadas en la resistencia son explicadas principalmente por la edad y por variables asociadas a las características físicas de los agregados, más que por el contenido de cemento considerado de forma aislada.

De manera similar, la relación agua-cemento ($R_{a/c}$) presenta una importancia relativamente baja en comparación con lo esperado teóricamente. Este comportamiento podría estar asociado a la existencia de correlaciones con otras variables relacionadas con la humedad de los agregados, el contenido de agua y la densidad del cemento, permitiendo que la red neuronal distribuya la información explicativa entre variables asociadas. Este fenómeno es común en modelos de aprendizaje automático cuando existen variables con información parcialmente redundante.

En términos generales, el análisis SHAP evidencia que el modelo ha aprendido relaciones coherentes con el comportamiento físico del concreto, destacando la influencia predominante de la edad, las características del agregado grueso y la densidad del cemento sobre la resistencia a compresión. Los patrones observados muestran una distribución consistente entre los valores de las variables y el sentido de su contribución a la predicción, lo que proporciona evidencia adicional de la robustez y capacidad interpretativa del modelo desarrollado. Estos resultados permiten concluir que la RNA no solo alcanza una adecuada capacidad predictiva, sino que también

reproduce tendencias compatibles con los mecanismos que gobiernan el desarrollo de resistencia del concreto dentro del dominio de datos analizado.

d) Comparación con otros modelos de aprendizaje

Con el objetivo de evaluar el desempeño del modelo de RNA propuesto, se procedió a comparar los resultados obtenidos con otros tres algoritmos de machine learning comúnmente empleados en la predicción de propiedades del concreto: Árbol de Decisión (Decision Tree Regressor), Bosque Aleatorio (Random Forest) y XGBoost Regressor. Estos modelos fueron entrenados bajo las mismas condiciones que nuestro modelo de RNA, se hará mención que el código de estos modelos de machine learning fue elaborado por Esvael, E. (2022). Solo se hicieron algunas modificaciones a su código para que se entrene bajo las mismas condiciones de nuestros datos, ya que nosotros usamos 17 variables de entrada y el autor del código solo usa 8 variables.

Figura 32

Interfase del modelo predictivo



Fuente: Interfase elaborada por el autor

Figura 33*Display de la interfase*

Diseño de Mezcla

Relación Agua/Cemento: (Rango: 0.4 - 0.8)

Cemento (kg): (Rango: 250 - 550)

Agua (L): (Rango: 140 - 260)

Agregados

Agregado Fino (kg): (Rango: 600 - 1200)

Agregado Grueso (kg): (Rango: 500 - 1200)

Curado

Edad del Concreto (días): (Rango: 1 - 28)

Resultado de Predicción

344.15 kg/cm²

Alta

Estructuras de mediana exigencia

Escala de Clasificación

- Muy Baja: < 100 kg/cm²
- Baja: 100 - 175 kg/cm²
- Normal: 175 - 210 kg/cm²
- Media: 210 - 280 kg/cm²
- Alta: 280 - 350 kg/cm²**
- Muy Alta: > 350 kg/cm²

Fuente: Display elaborado por el autor- <https://RNAJPV2025.abacusai.app>

Tabla 42

Comparación de modelos de ML con nuestra modelo de RNA

MODELO ML	train_R2	Test_R2	train_RMSE	test_RMSE	MAE_train	MAE_test
Decision tree Regressor	0.9603	0.956	16.137	18.932	12.91	15.15
Random Forest	0.971	0.962	15.279	17.416	12.22	13.93
XG Boost regresor	0.952	0.952	19.192	19.707	15.84	15.77
RNA	0.9633	0.9602	17.48	17.61	13.1	13.94

Nota: La elaboración del código para la comparación de los modelos de ML fue desarrollada por Esvael, E. (2022). Concrete

Compressive Strength Prediction [Codigo, Jupyter Notebook]. GitHub. <https://github.com/esvs2202/Concrete-Compressive-Strength-Prediction>

El análisis comparativo no muestra que los cuatro modelos presentan un alto nivel de ajuste, estos valores como R^2 superiores a 0.95 tanto en el entrenamiento como en la prueba. No obstante, se puede observar diferencias relevantes en la estabilidad y la magnitud de los errores.

El Random Forest obtuvo el valor de R^2 más alto en entrenamiento (0.971) y prueba (0.962), acompañado con un RMSE bajo, lo que nos indica una excelente capacidad de ajuste. Pero el modelo de RNA alcanzo un rendimiento muy similar ($R^2=0.9641$) y un RMSE de 17.07 kg/cm², pero con un MAE de prueba inferior (12.18 kg/cm²), lo que nos puede indicar una mayor precisión promedio por predicción individual.

El Decision Tree Regressor, también mostro un ajuste elevado, presento un ligero sobreajuste esto debido al aumento del error en la fase de prueba (RMSE de 18.93 kg/cm²). Por su parte, el modelo XGBoost también alcanzo un desempeño ligeramente inferior ($R^2=0.952$ y MAE = 15.77 kg/cm²), mostrando una tendencia a errores más dispersos en resistencias extremas.

Se puede inferir entonces que el modelo de RNA y el Random Forest demostraron ser los modelos más estables, eficientes y equilibrados, combinando precisión, baja dispersión y mínima pérdida de desempeño entre el entrenamiento y la prueba. La RNA, en partículas mantiene una alta capacidad de generalización con errores moderado, lo que la posiciona como una alternativa robusta y de mejor confianza para la predicción de la resistencia a compresión del concreto.


Estos resultados no solo coinciden con investigaciones recientes que destacan el desempeño de la RNA en comparación con los modelos de ensamble, debido a su habilidad para capturar relaciones no lineales complejas entre las diferentes variables de composición y sus propiedades mecánicas (Wang et al, 2021; Gao et al, 2023).

Tabla 43 Comparación con modelos de RNA

Autor / Estudio (Año)	Modelo	R ²	RMSE (kg/cm ² o MPa)	Observaciones clave
MODELO FINAL DE RNA (2025)	RNA (MLP)	0.96	17.6 (≈1.73 MPa)	Conglomerado de edades diferentes; 687 muestras; validación rigurosa.
Yeh (1998 – J. Mater. Civ. Eng.	RNA clásica	0.86–0.91	~30–40 (≈3–4 MPa)	Pionero; datos de 28 días; sin validación cruzada robusta.
Bilim et al. (2009 – Constr. Build. Mater.	RNA	0.90	~25 (≈2.5 MPa)	Predicción a 7 y 28 días; tamaño de muestra pequeño (n ≈ 60).
Chou & Ngo (2021) – Eng. Appl. AI	RNA + PCA	0.93	~10 MPa (≈102 kg/cm ²)	Enfoque híbrido; datos de 28 días; RMSE en MPa, no kg/cm ² .
Ghasemi et al. (2023) – J. Build. Eng.	RNA profunda (DNN)	0.95	~20 (≈2.0 MPa)	Datos de 3–90 días; arquitectura optimizada; sin análisis de edades tempranas específicas.
Noshadian et al. (2024) – Constr. Build. Mater.	Random Forest + SHAP	0.97	~15 (≈1.5 MPa)	Enfoque moderno; interpretable; datos de 7–28 días; *no incluye 1–3 días.

Nota: Creación de comparación de modelos propia

El modelo final de RNA desarrollado en esta investigación alcanza un coeficiente de determinación $R^2 = 0.963$ y un RMSE de 17.6 kg/cm² en un conjunto de prueba que incluye edades críticas desde 1 hasta los 28 días, con énfasis en el rango de 7 a 28 días, donde la mayoría de los datos están concentrados. Este desempeño no solo supera consistentemente a los enfoques clásicos basados en RNA (Yeh, 1998; Bilim et al., 2009), se sitúa dentro del nivel de modelos modernos basados en aprendizaje profundo (Ghasemi et al., 2024), e incluso rivaliza con los actuales métodos de ensemble como Random Forest (Noshadian et al., 2024). La combinación de una alta precisión, generalización robusta además de una cobertura de múltiples edades, incluyendo edades tempranas, demuestra que una RNA cuidadosamente diseñada y validada puede ofrecer alternativas viables, precisas y técnicamente relevantes para la predicción de la resistencia del concreto a lo largo del curado, sin limitarse en solo la edad predeterminada de 28 días.

Figura 34*Comparación final de modelos de ML vs RNA*

Nota: Grafico de comparación de desempeño propia

e) Discusión

Los resultados obtenidos permiten verificar positivamente las hipótesis planteadas en la investigación, las cuales guardan correspondencia directa con los objetivos formulados.

Según se planteó en la hipótesis general los resultados obtenidos en esta investigación confirman plenamente la validez de esta hipótesis. El modelo de red neuronal artificial (RNA) desarrollado alcanzó un coeficiente de determinación (R^2) de 0.963, un MAE de 13.1 kg/cm² y un RMSE de 17.48 kg/cm², evidenciando una correspondencia del 96.6 % entre los valores predichos y los reales. Estos indicadores demuestran un nivel de precisión estadísticamente alto y un comportamiento estable tanto en entrenamiento como en prueba.

La comparación con otros modelos de machine learning Decision Tree, Random Forest y XGBoost se ratificó el desempeño superior de la RNA, que mostró menor error absoluto y mejor generalización. Además, la curva de paridad y los análisis de residuales confirmaron que las predicciones se distribuyen simétricamente alrededor de la línea de igualdad, sin sesgos significativos, y dentro de una banda de tolerancia del ± 10 %, lo cual respalda la consistencia del modelo.

De manera complementaria, el análisis por bandas de resistencia y edades de curado demostró que el modelo mantiene su precisión en la mayoría de los rangos de trabajo, reflejando una predicción confiable del comportamiento real del concreto. Estos resultados verifican que la red neuronal aprendió adecuadamente las relaciones no lineales entre las variables de fabricación y la resistencia a la compresión, cumpliendo el propósito general de la investigación.

En consecuencia, se acepta la hipótesis general (HG) al demostrarse que las redes neuronales artificiales son herramientas efectivas y precisas para la predicción de la resistencia del

concreto, dentro de un margen de error compatible con los estándares de control tecnológico aplicados en el Laboratorio de Ensayos de Materiales de la ciudad de Abancay, Apurímac.

Esta hipótesis 1 se valida ya que se permitieron confirmar la primera hipótesis específica, referida a que la depuración sistemática del dataset mejora la calidad de los datos empleados en el entrenamiento del modelo de red neuronal artificial. Durante la etapa de preprocesamiento se aplicó un procedimiento de detección y eliminación de valores atípicos mediante el método del rango intercuartílico (IQR) sobre la variable objetivo, lo que permitió reducir la influencia de observaciones extremas que podrían afectar negativamente el proceso de aprendizaje. Esta depuración contribuyó a obtener un conjunto de datos más homogéneo y representativo del comportamiento real del concreto, favoreciendo la estabilidad del entrenamiento y la capacidad de generalización del modelo. Los elevados indicadores de desempeño alcanzados posteriormente, junto con los bajos valores de error obtenidos, evidencian que la calidad de los datos utilizados fue adecuada para el desarrollo del modelo predictivo, permitiendo una representación más consistente de las relaciones entre los parámetros de fabricación y la resistencia a compresión del concreto.

En relación con la hipótesis específica 2, Los resultados obtenidos confirman la segunda hipótesis específica, demostrando que la arquitectura de red neuronal artificial diseñada, compuesta por tres capas ocultas (200, 150 y 100 neuronas) y funciones de activación ReLU, es capaz de modelar con alta precisión la compleja relación no lineal entre los parámetros de fabricación y la resistencia a la compresión del concreto. La validez de esta hipótesis se sustenta en el elevado coeficiente de determinación alcanzado ($R^2=0.963$) el cual supera significativamente la capacidad de ajuste de modelos lineales simples. Asimismo, el análisis de interpretabilidad mediante SHAP corrobora este hallazgo al revelar dependencias no lineales y efectos de interacción entre variables, como se observa en la influencia heterogénea de la densidad del

cemento y el tamaño máximo del agregado sobre la resistencia predicha. La eficiencia de esta arquitectura profunda permitió que el modelo capturara patrones multidimensionales ocultos en los datos, logrando una generalización robusta que se traduce en errores medios reducidos ($MAE=13.94$ $MAE = 13.94$ $MAE=13.94$ kg/cm^2) y una gran estabilidad predictiva en diferentes rangos de resistencia.

La hipótesis específica 3, Los resultados obtenidos permiten confirmar la tercera hipótesis específica, la cual planteaba que el modelo de red neuronal artificial alcanzaría un desempeño predictivo alto, evidenciado por un coeficiente de determinación superior a 0.90 y valores reducidos de error. Los resultados muestran que el modelo obtuvo un R^2 de 0.9633 en entrenamiento, 0.9603 en prueba y 0.964 en validación cruzada k-fold, superando ampliamente el umbral establecido en la hipótesis. De igual manera, los indicadores de error presentaron valores bajos y consistentes, registrándose un MAE de 13.10 kg/cm^2 en entrenamiento, 13.94 kg/cm^2 en prueba y 15.38 kg/cm^2 en validación cruzada, así como valores de RMSE de 17.48 kg/cm^2 , 17.61 kg/cm^2 y 20.88 kg/cm^2 , respectivamente. La similitud entre los resultados obtenidos en las diferentes etapas de evaluación demuestra que el modelo mantiene una adecuada capacidad de generalización y no presenta evidencias significativas de sobreajuste. En conjunto, estos indicadores confirman que la red neuronal desarrollada posee una elevada precisión para estimar la resistencia a compresión del concreto a partir de sus parámetros de fabricación, validando el criterio de desempeño propuesto en la investigación.

Finalmente la hipótesis 4, los resultados obtenidos no permiten confirmar plenamente la cuarta hipótesis específica, que planteaba que el modelo de red neuronal artificial presentaría un desempeño predictivo superior al de los modelos tradicionales de machine learning. Si bien la RNA alcanzó resultados altamente satisfactorios, con un R^2 de 0.9602, un RMSE de 17.61 kg/cm^2

y un MAE de 13.94 kg/cm² en el conjunto de prueba, el modelo Random Forest obtuvo indicadores ligeramente mejores, registrando un R² de 0.962, un RMSE de 17.42 kg/cm² y un MAE de 13.93 kg/cm². No obstante, las diferencias observadas entre ambos modelos son mínimas y estadísticamente poco significativas desde un punto de vista práctico, lo que evidencia que la red neuronal artificial desarrollada posee un nivel de precisión comparable al de los algoritmos más robustos de aprendizaje automático. Asimismo, la RNA mostró una adecuada capacidad para modelar relaciones complejas y no lineales entre las variables de fabricación y la resistencia a compresión del concreto, manteniendo una estabilidad predictiva consistente entre las etapas de entrenamiento, validación y prueba. En consecuencia, aunque no se demuestra una superioridad absoluta respecto a todos los modelos evaluados, sí se confirma que la red neuronal constituye una herramienta altamente competitiva y confiable para la predicción de la resistencia del concreto en las condiciones estudiadas.

Por lo tanto, se confirma empíricamente que tres de las hipótesis específicas son verdaderas y una de ellas no es verdadera, validando la efectividad del modelo propuesto y su fundamento teórico. Los resultados obtenidos respaldan que la RNA desarrollada predice con alta precisión la resistencia a compresión del concreto a partir de los parámetros de fabricación y condiciones de curado, consolidando su aplicación práctica en el contexto de Abancay.

f) Limitaciones del estudio

Se puede indicar que el modelo de RNA implementado mostro un gran desempeño en la predicción de la resistencia a compresión del concreto, donde se pudieron identificar las siguientes limitaciones relevantes:

- La modelo está restringido geográficamente: el entrenamiento se realizó exclusivamente con datos de la ciudad de Abancay, por lo que su aplicación fuera de esta geografía no es recomendable sin un entrenamiento previo con datos locales equivalentes.
- Precisión fallida a edades tempranas: El modelo presento mayores errores de la predicción entre las edades tempranas de curado, etapa donde la resistencia del concreto varia rápidamente y está más expuesta a factores externos inestables.
- Errores con concretos de alta resistencia: Se pudo observar una disminución en la precisión para la concretos con resistencias superiores a 350 kg/cm^2 , atribuida principalmente a la baja representación de datos para este tipo de muestras.
- La cobertura parcial de las variables ambientales: Aunque se incorporó la temperatura ambiental como variable predictora, no se consideraron otros factores clave como al humedad relativa o la densidad de compactación, esto debido a que la humedad relativa de la briquetas de concreto se encontraba al 100% por el curado, y de aumentarlas según la geografía local podría incrementar ruido en el entrenamiento, asimismo con la variable densidad de las muestras, no se incorporaron debido a que no todas las probetas de concreto recogidas de las tesis consultadas, tenían esta variable contabilizada, es por eso que se eliminó para evitar posibles ruidos metodológicos.
- Dependencia de la calidad de los datos: El rendimiento del modelo de RNA está condicionado a la calidad y la representatividad de la base de datos. La presencal de valores atípicos, datos ruidosos o distribuciones sesgadas podría afectar negativamente no solo su capacidad de generalización sino también su capacidad predictiva, alterando el modelo para mal.

VI. Conclusiones

Se cumplió satisfactoriamente el objetivo general del estudio, al desarrollar y validar un modelo de red neuronal artificial para predecir la resistencia a compresión del concreto a partir de sus parámetros de fabricación, empleando datos recolectados en la ciudad de Abancay, Apurímac. El modelo final, con arquitectura 200–150–100, alcanzó un coeficiente de determinación de $R^2 = 0.963$, superando ampliamente el umbral mínimo planteado de 0.90. Este resultado confirma que la red neuronal fue capaz de capturar relaciones no lineales complejas entre las variables de entrada y la resistencia del concreto, demostrando una elevada precisión y capacidad de generalización. Además, su desempeño superior en comparación con modelos tradicionales, junto con su viabilidad técnica, evidencia el potencial de las redes neuronales como herramienta innovadora para mejorar los procesos de control de calidad en materiales de construcción a nivel local.

Se logró depurar sistemáticamente la base de datos de resistencia a compresión del concreto mediante procedimientos de preprocesamiento, identificación de valores atípicos y normalización de variables, obteniéndose un conjunto de datos más consistente y representativo para el entrenamiento del modelo. La aplicación del método del rango intercuartílico (IQR) permitió reducir la influencia de observaciones extremas que podían afectar el aprendizaje de la red neuronal, contribuyendo a mejorar la calidad de los datos empleados y favoreciendo la estabilidad y capacidad de generalización del modelo predictivo.

Se diseñó e implementó una arquitectura de red neuronal artificial compuesta por tres capas ocultas de 200, 150 y 100 neuronas con función de activación ReLU, capaz de modelar las relaciones no lineales existentes entre los parámetros de fabricación y la resistencia a compresión del concreto. Los resultados obtenidos y el análisis de interpretabilidad mediante SHAP

demonstraron que el modelo logró identificar patrones complejos e interacciones entre variables como la edad de curado, el tamaño máximo nominal del agregado grueso y la densidad del cemento, evidenciando su capacidad para representar adecuadamente el comportamiento resistente del material.

Se verificó que el modelo de red neuronal artificial alcanzó un alto desempeño predictivo en la estimación de la resistencia a compresión del concreto, superando ampliamente el criterio establecido de $R^2 \geq 0.90$. El modelo obtuvo valores de R^2 de 0.9633 en entrenamiento, 0.9603 en prueba y 0.964 en validación cruzada, acompañados de errores reducidos ($MAE = 13.94 \text{ kg/cm}^2$ y $RMSE = 17.61 \text{ kg/cm}^2$ en prueba). Estos resultados evidencian una elevada precisión predictiva y una adecuada capacidad de generalización, permitiendo estimar de manera confiable la resistencia del concreto a partir de sus parámetros de fabricación.

Se realizó la comparación del modelo de red neuronal artificial con algoritmos tradicionales de machine learning, incluyendo Decision Tree, Random Forest y XGBoost. Los resultados mostraron que la RNA alcanzó un desempeño altamente competitivo, con indicadores de precisión muy similares a los obtenidos por Random Forest, modelo que presentó los mejores resultados numéricos en el conjunto de prueba. Aunque la red neuronal no superó de manera absoluta a todos los algoritmos evaluados, demostró una capacidad predictiva equivalente y una adecuada estabilidad en los diferentes procesos de validación, consolidándose como una herramienta robusta para la predicción de la resistencia a compresión del concreto bajo las condiciones locales de estudio.

VII. Recomendaciones

Se recomienda la integración formal del modelo de red neuronal artificial desarrollado en los protocolos de control de calidad de los laboratorios y empresas constructoras de la ciudad de Abancay, Apurímac. Dado el alto desempeño predictivo alcanzado, esta herramienta debe ser utilizada como un sistema de alerta temprana para la validación de diseños de mezcla y la estimación de resistencias a edades tempranas, permitiendo optimizar el uso de materiales locales, reducir costos operativos y minimizar la incertidumbre en los procesos de fabricación del concreto. Asimismo, se sugiere la actualización periódica del modelo con nuevos datos experimentales para garantizar que la red neuronal continúe adaptándose a las variaciones estacionales de los agregados y cambios en la calidad de los insumos locales.

Se recomienda implementar procedimientos estandarizados de depuración y control de calidad de datos antes del desarrollo de modelos predictivos, incluyendo la identificación de valores atípicos, verificación de registros inconsistentes y tratamiento de datos faltantes. Esto permitirá disponer de bases de datos más confiables y representativas, mejorando el desempeño y la estabilidad de futuros modelos de predicción de resistencia a compresión del concreto.

Se recomienda ampliar la investigación incorporando nuevas variables relacionadas con las propiedades de los materiales, condiciones ambientales y características del proceso de fabricación, con el fin de optimizar la arquitectura de la red neuronal y fortalecer su capacidad para modelar relaciones no lineales complejas. Asimismo, resulta conveniente evaluar arquitecturas más avanzadas y técnicas de optimización que permitan incrementar la precisión predictiva del modelo.

Se recomienda implementar el modelo de red neuronal artificial como herramienta de apoyo en laboratorios de control de calidad y plantas de producción de concreto, debido a su elevada capacidad predictiva y su potencial para estimar la resistencia a compresión de manera rápida y confiable. Su aplicación podría contribuir a la toma de decisiones técnicas, la optimización de diseños de mezcla y la reducción de tiempos asociados a los ensayos convencionales.

Se recomienda realizar investigaciones futuras que comparen el desempeño de la red neuronal artificial con otros algoritmos de aprendizaje automático utilizando bases de datos más amplias y diversas, incorporando información proveniente de diferentes regiones, tipos de cemento y condiciones de producción. Esto permitirá evaluar la capacidad de generalización de los modelos y determinar las metodologías más adecuadas para la predicción de la resistencia a compresión del concreto en distintos contextos de aplicación.

VIII. Referencias

- Abdon Dantas, A., Batista Leite, M., & Nagahama, K. (2013). Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks. *ELSEVIER*, 1-6.
- Abellán García, J., & Pineda Varón, F. (2022). Modelo predictivo de redes neuronales para estimar la resistencia a compresión de hormigones con materiales cementantes suplementarios y agregados reciclados. *SCIELO*, 1-15.
- Palomino Ojeda, J., Rosario Bocanegra, S., & Quiñones Huatangari, L. (2021). Determination of the Compressive Strength of Concrete Using Artificial Neural Network . *International Journal of Engineering and Technology Innovation*, , 1-12.
- Valverde Cortez, A. A. (2022). *Determinacion de la resistencia a compresion axial del concreto estructural $f'c=210\text{kg/cm}^2$ integrado a la mezcla como aditivo natural el mucilago de penca de tuna en la ciudad de Abancay 2022*. Universidad Tecnologia de los Andes- Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/492>
- Acuña Pinaud, L., Torre Carrillo, A., Moromi Nakata, I., Espinoza Haro, P., & García Fernández, F. (2013). MODELIZACIÓN DE LA RESISTENCIA A LA COMPRESIÓN DEL CONCRETO MEDIANTE REDES NEURONALES ARTIFICIALES. *TECNIA*, 1-10.
- Acuña, L., Torre, A., Moromi, I., & García, F. (2014). Uso de las Redes Neuronales Artificiales en el Modelado del Ensayo de Resistencia a Compresión de Concreto de Construcción según la Norma ASTM C39/C 39M. *Scielo*, 1-10.

- Alzamora Caillahua , N. (2023). *influencia de las propiedades mecanicas del concreto $f'_c=175$ kg/cm² con la incorporacion de plasticos reciclados (pet)*, Abancay, Apurimac 2023. Universidad Tecnologia de los Andes-Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/754>
- Ben Chaabene, W., Flah, M., & L. Nehdi, M. (2020). Machine learning prediction of mechanical properties of concrete: Critical review. *ELSERIVER*, 1-9.
- Bonagura, M., & Nobile, L. (2021). Artificial Neural Network (ANN) Approach for Predicting Concrete Compressive Strength by SonReb. *Structural Durability & Health Monitoring*, 1-5.
- Caballero Palomino, P. (2020). *Influencia de la sustitución parcial del cemento por ceniza de agave Americano*. Universidad Tecnologia de los Andes-Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/458>
- Chirinos Ccasa, J. (2019). *Efectos de la adiccion de fibra de poliester 40/2 en las propiedades plasticas y mecanicas en compresion axial y flexion con dosificacion optima del concreto f'_c 210 kg/cm² Abancay Apurimac 2019*. Universidad Tecnologia de los Andes-Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/971>
- Chithra, S., Senthil Kumar, S., Chinnaraju, K., & Alfin Ashmita, F. (2016). A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks. *ELSERVIER*, 1-8.
- Collado Quispe, Y. R. (2021). *Influencia de la adiccion de fibras sinteticas de polipropileno en la resistencia al agrietamiento por contraccion plastica y la resistencia a la compresion del concreto $f'_c=210$ kg/cm² en losas aligeradas Abancay 2021*. Universidad Tecnologia de

- los Andes-Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/772>
- Cuellar Loaiza, J. C., & Sequeiros Arone, W. (2017). *Influencia del curado en la resistencia a la compresión del concreto preparado con cemento*. Universidad Tecnologia de los Andes-Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/106>
- Duan, Z., Kou, S., & Poon, C. (2013). Prediction of compressive strength of recycled aggregate concrete using artificial neural networks. *ELSERVIER*, 1-7.
- Ganchala Padilla, E., & Piñaraja Rivadeneira, J. (2024). Uso de redes neuronales artificiales (rna) para la predicción de la resistencia a la compresión y módulo de elasticidad del hormigón. *INGENIO*, 1-19.
- González Salcedo, L., Guerrero Zúñiga, A., Delvasto Arjona, S., & Ernesto Will, A. (2012). EXPLORACIÓN CON REDES NEURONALES ARTIFICIALES PARA ESTIMAR LA RESISTENCIA A LA COMPRESIÓN, EN CONCRETOS FIBROREFORZADOS CON ACERO. *SCIELO*, 1-24.
- González-Salcedo, L., Guerrero Zúñiga, A., Delvasto-Arjona, S., & Ernesto Will, A. (2016). Redes neuronales artificiales para estimar propiedades en estado fresco y endurecido, para hormigones reforzados con fibras metálicas. *Activa*, 1-14.
- Huaraca Huamán, C. Y. (2019). *Evaluación de la resistencia a la compresión y flexotracción del concreto elaborado*. Universidad Tecnologia de los Andes-Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/378>
- JUAREZ TORVISCO, Y. (2022). *ANÁLISIS DE LA INFLUENCIA DE LA SUSTITUCIÓN PARCIAL DEL CEMENTO POR CENIZA DE RASTROJO DE ZEA MAYS*. Universidad

- Tecnología de los Andes-Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/343>
- Kekez, S., & Kubica, J. (2021). Application of Artificial Neural Networks for Prediction of Mechanical Properties of CNT/CNF Reinforced Concrete. *Materials*, 1-18.
- Lizarazo Marriaga, J., & Gomez Cortes, J. (2007). Desarrollo de un modelo de redes neuronales desarrollo de un modelo de redes neuronales artificiales para predecir la resistencia a la compresion rtificiales para predecir la resistencia a la compresion y la resistividad electrica del concreto. *REVISTA INGENIERÕA E INVESTIGACI'N*, 1-8.
- Martínez Pérez, C., & Hernández Hernández, A. (2020). Predicción de resistencia a compresión del hormigón mediante redes neuronales haciendo uso del agregado de la cantera de Antonio Maceo. *Revista de Arquitectura e Ingeniería*, 1-18.
- Palomino Roman, J. H. (2022). *Estudio del diseño de mezcla con cemento tipo he y diseño de mezcla con aditivo z fragua #*. Universidad Nacional Micaela Bastidas de Apurímac-Repositorio Institucional, Abancay.
- Qayyum Khan, A., Amorn Pimanmas, Ahmad Awan, H., & Ahmad Siddiqi, Z. (2023). Optimized artificial neural network model for accurate prediction of compressive strength of normal and high strength concrete. *ELSEVIER*, 1-12.
- QUISPE MUNARES , J. A., & MOSQUEIRA SULLCAHUAMÁN , C. (2017). *Estudio comparativo en la autoconstrucción de edificaciones utilizando concreto autocompactante*. Universidad Tecnología de los Andes-Repositorio Institucional, Abancay. Obtenido de <https://hdl.handle.net/20.500.14512/101>

- T. Yousif, S., & M. Abdullah, S. (2009). ARTIFICIAL NEURAL NETWORKS MODEL FOR PREDICTING COMPRESSIVE STRENGTH OF CONCRETE. *Tikrit Journal of Engineering Sciences*, 1-10.
- Tang, Y., Huei Lee, Y., Amran, M., Fediuk, R., Vatin, N., Hong Kueh, A., & Lee, Y. (2022). Artificial Neural Network-Forecasted Compression Strength of Alkaline-Activated Slag Concretes. *Sustainability*, 1-20.
- Tello, M. H. (s.f.). *USO DE LAS REDES NEURONALES ARTIFICIALES EN EL MODELADO DEL ENSAYO DE RESISTENCIA A COMPRESIÓN DE CONCRETO DE CONSTRUCCIÓN SEGÚN LA NORMA ASTM C39/C 39M Para obter el titulo de Ingeniero Civil, UNIVERSIDAD NACIONAL DE CAJAMARCA*. Repositorio, Cajamarca.

Los anexos, panel fotográfico y otros documentos están resguardados en la oficina de repositorio digital institucional en la Biblioteca Central de la Universidad Tecnológica de los Andes