

**UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL
DE HUAMANGA**

FACULTAD DE CIENCIAS AGRARIAS

ESCUELA PROFESIONAL DE INGENIERÍA AGRÍCOLA



TESIS:

**Comparación de la resistencia a compresión del concreto
mediante el método ACI 211.1 y las redes neuronales
artificiales, Ayacucho, 2025**

Para optar el título profesional de:
INGENIERO AGRÍCOLA

PRESENTADO POR:
Bach. Avel QUIHUI MEJIA

ASESOR:
Dr. Richard Alex OSCCO PECEROS

AYACUCHO - PERÚ

2025

DEDICATORIA

A Dios todopoderoso, fuente de sabiduría, fortaleza y esperanza, por bendecir cada paso de mi vida y permitirme esta importante meta académica. Gracias por iluminar mi camino, brindarme salud, perseverancia y la oportunidad de superar cada desafío presentado durante mi formación profesional. Su infinita misericordia y amor han sido el sustento que me permitió mantener la fe y la confianza en los momentos más difíciles.

A mis queridos padres, Faustino Quihui Huamán y Felicitas Mejía Quispe, y a mis hermanos, quienes con su amor, esfuerzo y sacrificio constante han sido el pilar fundamental en mi formación personal y profesional.

Agradezco profundamente su apoyo incondicional, la confianza que siempre depositaron en mí y las enseñanzas que me brindaron, inculcándome valores como el trabajo, perseverancia y la honestidad. Este logro no solo me pertenece, sino que también es de ustedes.

AGRADECIMIENTO

Expreso mi sincero agradecimiento a todos los docentes de la Universidad Nacional de San Cristóbal de Huamanga, en especial de la Facultad de Ciencias Agrarias, por su dedicación a la cátedra y por transmitir con compromiso y vocación los conocimientos de esta valiosa disciplina de la ingeniería.

A la Universidad Nacional de San Cristóbal de Huamanga, mi alma máter, por haberme acogido en sus aulas y contribuir significativamente a mi formación académica y profesional.

Asimismo, agradezco a mi asesor de tesis el Dr. Richard Alex Oscco Peceros, por su orientación, apoyo y aportes durante el desarrollo de la presente investigación.

Finalmente, agradezco a todas las personas que contribuyeron directa o indirectamente en la ejecución de este trabajo, con su colaboración incondicional.

ÍNDICE GENERAL

DEDICATORIA	I
AGRADECIMIENTO	II
RESUMEN	XII
ABSTRACT	XIII
INTRODUCCIÓN	1
1 Marco teórico	3
1.1 Bases teóricas	3
1.1.1 Antecedentes Internacionales	3
1.1.2 Antecedentes Nacionales	5
1.2 Método ACI 211.1	6
1.3 El concreto como material compuesto	7
1.3.1 Variables que afectan la resistencia	8
1.4 Resistencia a compresión del concreto - ACI 211.1	8
1.4.1 Concreto hidráulico	8
1.4.2 Componentes del concreto	9
1.4.2.1 Cemento Portland	9
1.4.2.2 Agregados	9
1.4.2.3 Agua de mezclado	9
1.4.2.4 Aditivos químicos	9
1.4.3 Propiedades del concreto fresco	10
1.4.3.1 Trabajabilidad	10
1.4.3.2 Asentamiento	10
1.4.4 Resistencia a compresión del concreto	10
1.4.5 Ley de Abrams y relación agua-cemento	11
1.4.6 Método ACI 211.1	11
1.4.7 Etapas del método ACI 211.1	12
1.4.7.1 Resistencia promedio requerida	12
1.4.7.2 Contenido de cemento	13

1.4.7.3	Volumen absoluto	13
1.4.7.4	Corrección por humedad de agregados	13
1.4.8	Ensayo de resistencia a compresión	15
1.4.9	Limitaciones del método ACI 211.1	15
1.5	Redes neuronales artificiales para estimar $F'c$	16
1.5.1	Inteligencia artificial y aprendizaje automático	16
1.5.2	Redes neuronales artificiales	16
1.5.2.1	Analogía con la neurona biológica	16
1.5.2.2	Modelo matemático de una neurona artificial	17
1.5.3	Funciones de activación	18
1.5.4	Arquitectura de redes neuronales	18
1.5.4.1	Perceptrón multicapa (MLP)	18
1.5.4.2	Propagación hacia adelante	19
1.5.5	Mecanismos de aprendizaje	19
1.5.5.1	Aprendizaje supervisado	20
1.5.5.2	Aprendizaje no supervisado	20
1.5.6	Entrenamiento y retropropagación	20
1.5.7	Métricas de evaluación	20
1.5.8	Variables de entrada para redes neuronales en concreto	21
1.5.9	Normalización de datos	22
1.5.10	Sobreajuste y regularización	22
1.5.11	Aplicación de RNA a la resistencia del concreto	23
1.6	Integración teórica para la investigación	24
2	METODOLOGÍA	26
2.1	Ubicación	26
2.1.1	Ubicación política	26
2.1.2	Ubicación geográfica	26
2.2	Vías de acceso	28
2.3	Características climáticas	28
2.4	Metodología	29
2.4.1	Tipo de investigación	29
2.4.2	Nivel de investigación	29
2.4.3	diseño de investigación	29
2.4.4	Población, muestra y técnicas de muestreo	29
2.4.4.1	Población	29
2.4.4.2	Muestra	30
2.4.5	Técnicas e instrumentos	30
2.4.5.1	Técnicas	30

2.4.5.2	Instrumentos	31
2.4.5.3	Técnicas de procesamiento y análisis de datos	32
2.4.5.4	Ética y permisos	32
2.5	Materiales y equipos	33
2.6	Desarrollo de la investigación	35
2.6.1	Variables de entrada y salida de la red neuronal artificial	35
2.6.2	Rango de trabajabilidad y volumen de entrada y salida	37
2.6.3	Obtención de la dataset para el modelo RNA	38
2.6.4	Normalización de la dataset para el modelo RNA	39
2.6.5	Contrastación de hipótesis por ANOVA	42
2.6.5.1	Descripción de los datos	42
2.6.5.2	Planteamiento de hipótesis	43
2.6.5.3	Análisis de varianza (ANOVA) del modelo global	43
2.6.5.4	Tabla de coeficientes del modelo global	43
2.6.5.5	ANOVA por cada variable independiente	44
2.6.6	Implementación del modelo de RNA	46
2.6.7	Estructura General del Código	47
2.6.7.1	Instalación e Importación de Librerías	47
2.6.7.2	Librerías utilizadas	47
2.6.7.3	Código relevante	47
2.6.7.4	Carga Manual del Archivo en Colab	47
2.6.7.5	Código relevante	48
2.6.7.6	Carga y Exploración de Datos	48
2.6.7.7	Código relevante	48
2.6.7.8	Salida esperada	48
2.6.7.9	Separación de Características y Objetivo	48
2.6.7.10	Código relevante	48
2.6.7.11	Forma resultante	48
2.6.7.12	División en Entrenamiento, Validación y Prueba	49
2.6.7.13	Código relevante	49
2.6.7.14	Número de muestras (para 806 totales)	49
2.6.7.15	Normalización de Datos	49
2.6.7.16	Código relevante	49
2.6.7.17	Arquitectura de la Red Neuronal	49
2.6.7.18	Compilación del Modelo	50
2.6.7.19	Callbacks	51
2.6.7.20	Código relevante	51
2.6.7.21	Entrenamiento	51
2.6.7.22	Código relevante	52

2.7	Predicciones	52
2.7.0.1	Código relevante	52
2.8	Desarrollo del diseño de mezcla	53
2.9	Parámetros de diseño y su justificación técnica	53
2.9.1	Selección del Asentamiento (Slump)	53
2.9.2	Relación Agua/Cemento (a/c)	53
2.9.3	Contenido de Cemento	53
2.10	Selección y justificación de agregados	54
2.10.1	Agregado Grueso	54
2.10.2	Agregado Fino	54
2.10.3	Tabla de Volúmenes Absolutos	55
2.11	Corrección por humedad - Justificación	55
2.11.1	Peso Húmedo de Agregados	55
2.11.2	Aporte de Humedad	55
2.11.3	Agua Efectiva	55
2.12	Proporcionamiento final y su justificación	56
2.12.1	Proporción en Peso	56
2.12.2	Proporción en Volumen (Obra)	56
2.13	Dosificación para ensayos de rotura	56
2.13.1	Volumen de Probeta	56
2.13.2	Factor de Corrección por Probeta	57
2.13.3	Cálculo de Materiales por Probeta	57
2.14	Cálculo de la resistencia esperada (f'_{cr})	57
2.14.1	Método Estadístico	57
2.14.2	Verificación con la Relación a/c	58
2.15	Relación entre diseño y resistencia de rotura	58
2.15.1	Cálculo de la Carga de Rotura	58
2.15.2	Relación entre la resistencia promedio requerida y la resistencia es- pecificada	58
2.16	Justificación de la dosificación en obra	58
2.16.1	Tolerancias Aceptables	58
2.16.2	Control de Calidad	59
2.17	Consideraciones finales	59
2.17.1	Validación del Diseño	59
2.17.2	Recomendaciones	59
2.18	Conclusiones	59
2.19	Obtención de datos en laboratorio	60

3 RESULTADOS

62

3.1	Evaluación del Modelo de red neuronal artificial	62
3.1.1	Parámetros estadísticos descriptivos de los datos de entrada	62
3.1.2	Tabla de resultados esperado	63
3.2	Visualización de Resultados	63
3.2.1	Gráficos: Curvas de entrenamiento	63
3.2.2	Comparación predicciones vs reales	70
3.2.3	Gráfico 3: Comparación secuencial	74
3.2.4	Gráfico 4: Barras de errores	77
3.2.5	Gráfico 5: Histograma de errores residuales	78
3.2.6	Gráfico 6: Boxplot de errores	81
3.2.7	Gráfico 7: Todos los datos en un scatter	82
3.2.8	Resultados para el objetivo específico 1 y 2	84
3.2.9	Resultados para el objetivo específico 3	85
3.2.10	Resultados para el objetivo específico 4	85
REFERENCIAS		90
3.3	Panel fotográfico	93
3.3.1	Diseño de mezcla	93
3.3.2	Cuarteo	95
3.3.3	Dosificación	96
3.3.4	Granulometría	97
3.3.5	Absorción y gravedad específica	98
3.3.6	Probetas	99
3.3.7	Rotura de probetas	100
3.4	Ubicación distrito de Ayacucho	101
3.5	Datos de entrada para la red neuronal artificial	101

ÍNDICE DE TABLAS

Tabla 1	Variables de entrada y salida para el modelamiento de la red neuronal artificial	8
Tabla 2	Rangos usuales de asentamiento según tipo de elemento estructural .	10
Tabla 3	Variables principales del diseño de mezclas ACI 211.1	14
Tabla 4	Símbolos utilizados en el marco teórico del concreto	14
Tabla 5	Analogía entre neurona biológica y neurona artificial	17
Tabla 6	Funciones de activación usadas en redes neuronales	18
Tabla 7	Interpretación de métricas para predicción de resistencia del concreto	21
Tabla 8	Variables recomendadas para una RNA aplicada al concreto	22
Tabla 9	Comparación conceptual entre método ACI 211.1 y RNA	24
Tabla 10	Parámetros de entrada y variable de salida de la red neuronal	36
Tabla 11	Materiales de entrada para el concreto $f'_c = 210 \text{ kg/cm}^2$	37
Tabla 12	Parámetros de entrada y salida de la red neuronal artificial	38
Tabla 13	Datos de entrada normalizados entre 0 y 1: E1–E12	39
Tabla 14	Datos de entrada y salida normalizados entre 0 y 1: E13–S1	41
Tabla 15	ANOVA de la regresión lineal múltiple para la variable dependiente S1	43
Tabla 16	Coefficientes estimados del modelo de regresión múltiple	43
Tabla 17	ANOVA individual por variable independiente	44
Tabla 18	Arquitectura de la red neuronal	50
Tabla 19	Suma de volúmenes absolutos sin agregado fino	55
Tabla 20	Proporción en peso de materiales	56
Tabla 21	Proporción en volumen para obra	56
Tabla 22	Dosificación para probetas de laboratorio	57
Tabla 23	Datos obtenidos en laboratorio para la rotura de concreto F'_c	60
Tabla 24	Parámetros estadísticos descriptivos	62
Tabla 25	Ejemplo de métricas de evaluación	63
Tabla 26	Métricas de evaluación del modelo de red neuronal artificial	67
Tabla 27	Análisis detallado de las métricas de evaluación	68
Tabla 28	Resumen de la evaluación del modelo RNA	69
Tabla 29	Comparación del desempeño con estudios previos	69
Tabla 30	Comparación de resultados con criterios de aceptación	70

Tabla 31	Tabla de resultados para iteración de 200 épocas	83
Tabla 32	Tabla de resultados para iteración de 300 épocas	83
Tabla 33	Resistencia a compresión obtenida con agregados de la cantera Chillico Huaycco	84
Tabla 34	Parámetros de entrada parte 1 a la RNA	101
Tabla 35	Parámetros de entrada parte 2 a la RNA	102
Tabla 36	Parámetros de entrada parte 3 a la RNA	104
Tabla 37	Parámetros de entrada parte 4 a la RNA	105
Tabla 38	Parámetros de entrada parte 5 a la RNA	107
Tabla 39	Parámetros de entrada parte 6 a la RNA	108

ÍNDICE DE FIGURAS

Figura 1	Diagrama de flujo del método ACI 211.1 para diseño de mezclas . . .	6
Figura 2	Representación esquemática de la zona de transición interfacial (ITZ).	7
Figura 3	Relación conceptual entre agua-cemento y resistencia a compresión .	11
Figura 4	Secuencia general del método ACI 211.1	12
Figura 5	Esquema de probeta cilíndrica sometida a compresión axial	15
Figura 6	Modelo matemático de una neurona artificial	18
Figura 7	Arquitectura MLP para predicción de resistencia a compresión	19
Figura 8	Curvas conceptuales de pérdida y posible sobreajuste	23
Figura 9	Modelo conceptual de comparación entre ACI 211.1 y RNA	25
Figura 10	Área de estudio	27
Figura 11	Rotura de probetas	60
Figura 12	Error cuadrático medio con 200 iteraciones	64
Figura 13	Error cuadrático medio con 300 iteraciones	65
Figura 14	Error absoluto medio con 200 iteraciones	65
Figura 15	Error absoluto medio con 300 iteraciones	66
Figura 16	Raíz del error cuadrático medio	66
Figura 17	Raíz del error cuadrático medio	67
Figura 18	Entrenamiento de la RNA para 200 iteraciones	71
Figura 19	Entrenamiento de la RNA para 300 iteraciones	71
Figura 20	Validación de la RNA para 200 iteraciones	72
Figura 21	Validación de la RNA para 300 iteraciones	72
Figura 22	Prueba de la RNA para 200 iteraciones	73
Figura 23	Prueba de la RNA para 300 iteraciones	73
Figura 24	Regresión de entrenamiento para 200 épocas	74
Figura 25	Regresión de entrenamiento para 300 épocas	75
Figura 26	Regresión de validación para 200 épocas	75
Figura 27	Regresión de validación para 300 épocas	76
Figura 28	Regresión de prueba para 200 épocas	76
Figura 29	Regresión de prueba para 300 épocas	77
Figura 30	Comparaciones de errores con 200 épocas	77
Figura 31	Comparaciones de errores con 300 épocas	78

Figura 32	Error residual con 200 épocas para entrenamiento	78
Figura 33	Error residual con 300 épocas para entrenamiento	79
Figura 34	Error residual con 200 épocas para validación	79
Figura 35	Error residual con 300 épocas para validación	80
Figura 36	Error residual con 200 épocas para prueba	80
Figura 37	Error residual con 300 épocas para prueba	81
Figura 38	Distribución de error para 200 épocas	81
Figura 39	Distribución de error para 300 épocas	82
Figura 40	Regresión para 200 épocas	82
Figura 41	Regresión para 300 épocas	83
Figura 42	Diseño de mezcla	93
Figura 43	Pesando los materiales	94
Figura 44	Cuarteo del agregado grueso	95
Figura 45	Cuarteo de la piedra chancada	95
Figura 46	Pesando el agregado	96
Figura 47	Insumos para la mezcla	96
Figura 48	Granulometría	97
Figura 49	Curado de las probetas	98
Figura 50	Probetas	99
Figura 51	Rotura de probetas	100
Figura 52	Área de estudio	101

RESUMEN

La resistencia a compresión es una de las propiedades mecánicas más importantes del concreto, debido a que determina su capacidad para soportar cargas estructurales. La presente investigación tuvo como objetivo comparar la resistencia a compresión del concreto obtenida mediante el método ACI 211.1 y la estimada mediante redes neuronales artificiales (RNA) en Ayacucho, 2025.

La investigación fue de enfoque cuantitativo, nivel predictivo y diseño con componente experimental. La unidad de análisis estuvo constituida por las probetas ensayadas para determinar la resistencia a compresión. La población estuvo conformada por 806 resultados de probetas correspondientes a la construcción de la Escuela Profesional de Ingeniería Agrícola, obtenidos de un laboratorio de agregados. Se empleó una muestra censal constituida por los 806 resultados. Como variables de entrada se consideraron el contenido de cemento, agua, agregado fino, agregado grueso, aditivos y relación agua-cemento. Para la predicción se implementó una red neuronal artificial tipo Perceptrón Multicapa (MLP), mediante aprendizaje supervisado. El desempeño se evaluó mediante MSE, RMSE, MAE y coeficiente de determinación (R^2).

Los resultados mostraron un desempeño predictivo con valores de R^2 superiores al 83.6 % y errores reducidos respecto a los valores experimentales. Asimismo, el ANOVA evidenció diferencias estadísticamente significativas ($p < 0,05$).

Se concluye que las redes neuronales artificiales constituyen una herramienta eficiente para estimar la resistencia a compresión del concreto, contribuyendo a reducir tiempos de evaluación y apoyar la toma de decisiones en ingeniería civil.

Palabras clave: resistencia a compresión, concreto, ACI 211.1, redes neuronales artificiales, aprendizaje automático, diseño de mezclas.

ABSTRACT

Compressive strength is one of the most important mechanical properties of concrete, as it determines its ability to withstand structural loads. The objective of this research was to compare the compressive strength of concrete obtained using the ACI 211.1 method with that estimated using artificial neural networks (ANN) in Ayacucho, 2025.

The research followed a quantitative approach, with a predictive level and a design including an experimental component. The unit of analysis consisted of concrete specimens tested to determine their compressive strength. The population consisted of 806 concrete specimen test results corresponding to the construction of the Professional School of Agricultural Engineering, obtained from an aggregates laboratory. A census sample comprising all 806 results was used. The input variables included cement content, water, fine aggregate, coarse aggregate, admixtures, and water-cement ratio. For prediction, a Multilayer Perceptron (MLP) artificial neural network was implemented using supervised learning. Model performance was evaluated using MSE, RMSE, MAE, and the coefficient of determination (R^2).

The results showed good predictive performance, with R^2 values above 83.6 % and low errors compared with the experimental values. Furthermore, ANOVA showed statistically significant differences ($p < 0,05$).

It is concluded that artificial neural networks constitute an efficient tool for estimating the compressive strength of concrete, contributing to reducing evaluation time and supporting decision-making in civil engineering.

Keywords: concrete, compressive strength, artificial neural networks, ACI.

INTRODUCCIÓN

El concreto es el material de construcción más utilizado a nivel mundial debido a su resistencia, durabilidad y versatilidad en obras de infraestructura y edificaciones. Su desempeño estructural depende, en gran medida, de un diseño adecuado de la mezcla y de la calidad de los materiales empleados. En los últimos años, la incorporación de herramientas computacionales e inteligencia artificial ha permitido optimizar la predicción de propiedades mecánicas, especialmente la resistencia a compresión, mejorando la eficiencia en el diseño del concreto (Neville, 2011).

La presente investigación contribuye principalmente al Objetivo de Desarrollo Sostenible 9 (Industria, innovación e infraestructura) al promover la aplicación de métodos innovadores para optimizar el diseño del concreto mediante redes neuronales artificiales. Asimismo, aporta al ODS 11 (Ciudades y comunidades sostenibles), al favorecer el desarrollo de infraestructuras más seguras, eficientes y resilientes mediante el uso de tecnologías que mejoran la calidad y el desempeño de los materiales de construcción (Naciones Unidas, 2015).

En Estados Unidos, la dosificación del concreto mediante el método ACI 211.1 continúa siendo una de las metodologías más empleadas para el diseño de mezclas debido a su confiabilidad y amplia validación experimental. Sin embargo, investigaciones recientes incorporan modelos de aprendizaje automático y redes neuronales artificiales para estimar la resistencia a compresión con mayor precisión, reduciendo costos experimentales y optimizando el proceso de diseño de mezclas de concreto (Zhang et al., 2023).

En el Perú, el diseño de mezclas de concreto se realiza principalmente mediante procedimientos normados, como el método ACI 211.1, debido a su confiabilidad para alcanzar la resistencia especificada. Sin embargo, el creciente desarrollo de la inteligencia artificial ha impulsado investigaciones que incorporan redes neuronales artificiales para mejorar la predicción de la resistencia a compresión, optimizar el consumo de materiales y reducir los costos asociados a los ensayos experimentales (Ministerio de Vivienda, Construcción y Saneamiento, 2023).

En Ayacucho, la producción de concreto depende en gran medida de los agregados provenientes de canteras locales, como Chillico Huaycco, cuyas propiedades físicas y mecánicas influyen directamente en la resistencia del concreto. No obstante, son escasas las investigaciones que comparan el diseño convencional mediante el método ACI 211.1 con modelos predictivos basados en redes neuronales artificiales, limitando la incorporación de tecnologías de inteligencia artificial para optimizar el diseño de mezclas adaptadas a las condiciones

locales (Ministerio de Vivienda, Construcción y Saneamiento, 2023).

La resistencia a compresión del concreto constituye una de las propiedades mecánicas más importantes para garantizar la seguridad y durabilidad de las estructuras. Sin embargo, la variabilidad en las características de los agregados, las proporciones de mezcla y las condiciones de fabricación pueden ocasionar diferencias significativas entre la resistencia diseñada y la obtenida experimentalmente. Además, los métodos convencionales de dosificación presentan limitaciones para modelar relaciones complejas entre múltiples variables, lo que afecta la precisión en la estimación de la resistencia del concreto (Neville, 2011).

La presente investigación busca comparar la resistencia a compresión del concreto obtenida mediante el método ACI 211.1 y un modelo basado en redes neuronales artificiales, con el propósito de determinar si las técnicas de inteligencia artificial ofrecen una mayor precisión en la predicción del comportamiento mecánico del concreto. De no desarrollarse este estudio, continuará predominando el uso exclusivo de métodos tradicionales, desaprovechando herramientas computacionales capaces de optimizar el diseño de mezclas, reducir costos experimentales y mejorar la calidad y confiabilidad de las estructuras de concreto (Zhang et al., 2023).

La investigación contribuirá al fortalecimiento del conocimiento científico sobre la aplicación del método ACI 211.1 y de las redes neuronales artificiales en la predicción de la resistencia a compresión del concreto. Asimismo, ampliará la evidencia sobre el uso de modelos de inteligencia artificial en ingeniería de materiales, proporcionando información que podrá servir como referencia para futuras investigaciones relacionadas con el diseño óptimo de mezclas de concreto (ACI Committee 211, 2022).

Desde el punto de vista práctico, los resultados permitirán determinar si las redes neuronales artificiales constituyen una alternativa eficiente para estimar la resistencia a compresión del concreto, reduciendo el número de ensayos experimentales, optimizando el diseño de mezclas y favoreciendo la toma de decisiones en proyectos de ingeniería civil desarrollados con materiales locales.

Cumpliendo con el objetivo general que es comparar la resistencia a compresión del concreto mediante el método ACI 211.1 y las redes neuronales artificiales, utilizando agregados de la cantera Chillico Huaycco, Ayacucho, 2025.

Donde también se cumplieron los objetivos específicos mencionados:

1. Caracterizar las propiedades físicas y mecánicas de los agregados provenientes de la cantera Chillico Huaycco, Ayacucho, 2025.
2. Diseñar una mezcla de concreto utilizando el método ACI 211.1, Ayacucho, 2025.
3. Desarrollar un modelo predictivo basado en redes neuronales artificiales para estimar la resistencia a compresión del concreto, considerando las proporciones de mezcla y las propiedades de los materiales, Ayacucho, 2025.

Capítulo 1

Marco teórico

1.1 Bases teóricas

1.1.1 Antecedentes Internacionales

Mouawad et al. (2025), en su artículo científico desarrollaron un modelo basado en redes neuronales artificiales para predecir la resistencia a compresión del concreto sostenible utilizando 768 muestras experimentales, desarrollando un modelo predictivo basado en RNA para concretos sostenibles. con una metodología que utilizaron 768 muestras experimentales y se implementó un modelo de redes neuronales. Se demostró que las redes neuronales permiten modelar adecuadamente las relaciones no lineales entre los componentes de la mezcla y la resistencia mecánica donde constituye una herramienta eficiente para el diseño y optimización del concreto.

Khan et al. (2023), en su artículo científico *Optimized artificial neural network model for accurate prediction of compressive strength of normal and high strength concrete*, Desarrolla un modelo de RNA para predecir la resistencia a compresión del concreto normal y de alta resistencia. Se empleó una metodología una base de datos de 1637 muestras, ocho variables de entrada y el algoritmo Levenberg-Marquardt, donde se obtuvo un coeficiente de determinación de 0.928, confirmando la generalización del modelo mediante validación cruzada. En conclusión el modelo propuesto es una herramienta precisa, económica y práctica para la predicción de la resistencia del concreto .

Kumar et al. (2024), en su artículo científico *Prediction of mechanical properties of high-performance concrete and ultrahigh-performance concrete using soft computing techniques: A critical review*. como objetivo Realiza una revisión exhaustiva de las técnicas de computación blanda para predecir propiedades mecánicas de HPC y UHPC, con la metodología realizó una revisión sistemática de la literatura especializada en algoritmos de ML y DL. obteniendo resultados con la revisión identificó clusters de investigación y destacó la efectividad de redes neuronales y modelos de aprendizaje profundo, concluyendo el estudio a ofrecer una guía para que ingenieros seleccionen métodos precisos para sus necesidades .

Zhang et al. (2025), en su artículo científico *Prediction of high-performance concrete compressive strength using Decision Tree-Guided Artificial Neural Network Pretraining ap-*

proach, Propone un enfoque de preentrenamiento de RNA guiado por árboles de decisión para conjuntos de datos pequeños. En la Metodología se validó experimentalmente el método TANNP para sinergizar las ventajas de los árboles de decisión, resultando mejorar significativamente el coeficiente de determinación de 0.91 a 0.97 y redujo el RMSE en un 36.1 %. La conclusión es que el método mitiga la dependencia de grandes volúmenes de datos logrando resultados de vanguardia .

Hosseinzadeh et al. (2024a), en su artículo científico *Concrete strength and durability prediction through deep learning and artificial neural networks*, tiene por objetivo predecir simultáneamente la resistencia a compresión y el coeficiente de migración de cloruros del concreto. aplica una metodología donde se recopiló una base de datos experimental de casi 1100 puntos de la literatura y se aplicaron técnicas de Deep Learning y RNA, teniendo como resultado la precisión en regresión y clasificación superando a 0.85, demostrando una alta capacidad predictiva, concluyendo que la inteligencia artificial constituye una herramienta eficiente para optimizar el diseño y evaluar estructuras .

Naved et al. (2024), en su artículo científico *Propusieron modelos de redes neuronales profundas (Deep Neural Networks, DNN) optimizados mediante ajuste de hiperparámetros para la predicción de la resistencia a compresión del concreto*, propone como objetivo modelos DNN optimizados para predecir la resistencia del concreto, y como metodología tomó del estudio y evaluó múltiples variables asociadas a la composición de la mezcla y al tiempo de curado, comparando los resultados con otros enfoques de inteligencia artificial. Los Resultados de los modelos de aprendizaje profundo presentaron un desempeño superior respecto a métodos convencionales, concluyendo que el aprendizaje profundo es superior a otras técnicas de aprendizaje automático utilizadas en investigaciones previas.

Fu et al. (2025), en su artículo científico *Desarrollaron un marco de aprendizaje automático interpretable para predecir la resistencia a compresión del concreto empleando árboles de potenciación (Gradient Boosting Trees), Random Forest y Redes Neuronales Backpropagation* tiene por objetivo desarrollar un marco de aprendizaje automático interpretable para predecir la resistencia. En la metodología se emplearon árboles de potenciación, Random Forest y Redes Neuronales Backpropagation, y en los resultados mostraron una elevada precisión predictiva, encontrando que las redes neuronales fueron capaces de representar adecuadamente las relaciones complejas y no lineales, y finalmente en la conclusión se valida el uso de técnicas de inteligencia artificial para el diseño y control de calidad del concreto.

Wang et al. (2025), en su artículo científico *Evaluating the strength properties of high-performance concrete in the form of ensemble and hybrid models using deep learning techniques*. Tiene por objetivo predecir la resistencia a compresión y fluidez del concreto de alto rendimiento. En la metodología se desarrollaron modelos híbridos y ensemble con T-SFIS, GBMBoost y Decision Tree, combinados con algoritmos metaheurísticos GWO y QPSO, tomando como resultado el modelo GBQP se logró un rendimiento superior con $R^2=0.998$ y $RMSE=1.216$ MPa para resistencia, concluyendo que las técnicas avanzadas mejoran signi-

ficativamente la eficiencia y precisión en la predicción de propiedades del HPC .

1.1.2 Antecedentes Nacionales

Bernilla Rodriguez (2024), en su investigación *Modelo predictivo basado en redes neuronales artificiales para estimar la resistencia a compresión del concreto a los 28 días*, toma como objetivo Estimar la resistencia a compresión del concreto a los 28 días mediante RNA, con la metodología de utilizar propiedades de los agregados, tipo de cemento y proporciones de agua, cemento y agregados como variables de entrada. La arquitectura neuronal fue implementada en TensorFlow con dos capas ocultas de 16 y 8 neuronas, resultando una precisión superior al 90 % en resistencias comprendidas entre 210 y 335 kg/cm². La conclusión es que la RNA representan una alternativa eficiente para la predicción de la resistencia del concreto.

Loayza Cáceres y Ramos Butrón (2023), en su investigación *Alternativa al diseño convencional de mezclas de concreto mediante inteligencia artificial y redes neuronales artificiales*. Se propone como objetivo una alternativa al diseño convencional de mezclas de concreto, utilizando como metodología los bases de datos de investigaciones desarrolladas en Arequipa y diseñaron modelos para concretos de 175, 210 y 280 kg/cm². Los resultados evidenciaron que las RNA permiten optimizar las proporciones de mezcla. Las conclusiones del RNA permiten obtener predicciones confiables de la resistencia mecánica del concreto.

Del Aguila Vela y Flores Castillo (2024), en su investigación *Red neuronal profunda para modelar la resistencia a compresión de un concreto de $f'c = 210$ kg/cm² en la región San Martín*. Toma como objetivo modelar la resistencia a compresión de un concreto de $f'c = 210$ kg/cm². En la metodología el modelo estuvo conformado por tres capas ocultas de 64, 32 y 16 neuronas respectivamente. Los resultados mostraron errores cuadráticos medios entre 10.5 y 13.2 kg/cm² y una precisión aproximada del 85 %. En conclusión la RNA son herramientas viables para el modelado de la resistencia del concreto.

Aristizaval Albarran y Intor Villatty (2023), en su investigación *Red neuronal artificial para predecir la resistencia a compresión de concretos de 175 y 210 kg/cm² en Cajamarca*. Proponiéndose como objetivo predecir la resistencia a compresión de concretos de 175 y 210 kg/cm² donde se elaboraron 54 probetas ensayadas a 7, 14 y 28 días de curado. Los resultados mostraron errores máximos promedio inferiores al 5 concluyendo que la RNA pueden predecir con alta precisión el comportamiento resistente del concreto.

Díaz Tello (2017), en su investigación *Sistema basado en redes neuronales artificiales para pronosticar la resistencia a compresión del concreto según la norma ASTM C39/C39M*. Toma como objetivo pronosticar la resistencia a compresión del concreto según la norma ASTM. Donde en la metodología se implementó una red neuronal multicapa, resultando que la red neuronal logró errores inferiores al 5 % respecto a los valores experimentales. Concluyendo que se evidenció la capacidad de las RNA para estimar la resistencia del concreto en distintas edades de curado.

Lupaca Lopez y Quispe Huacasi (2022), en su investigación *Evaluación de la eficacia de*


las redes neuronales artificiales en la predicción de la resistencia a compresión y trabajabilidad de concretos ligeros con poliestireno expandido modificado. Propone como objetivo evaluar la eficacia de las RNA en la predicción de la resistencia y trabajabilidad de concretos ligeros, donde se evaluó la eficacia de las RNA en este tipo de concretos. Los resultados demostraron que las RNA constituyen herramientas eficaces para modelar propiedades mecánicas del concreto, y la conclusión es que la RNA permiten optimizar procesos de diseño de mezclas.

1.2 Método ACI 211.1

El procedimiento ACI 211.1 se basa en tablas y gráficos que relacionan el asentamiento, el tamaño máximo del agregado, el módulo de fineza y la relación a/c. El diagrama de flujo de la metodología se presenta en la figura 1.

Figura 1

Diagrama de flujo del método ACI 211.1 para diseño de mezclas



Nota. Basado en ACI 211.1.

1.3 El concreto como material compuesto


El concreto es una mezcla de cemento, agua, agregados (finos y gruesos) y, en ocasiones, aditivos. Su resistencia a compresión depende críticamente de la relación agua/cemento (a/c), conforme a la ley de Abrams:

$$f'_c = \frac{k_1}{k_2^{a/c}} \quad (1.1)$$

donde k_1 y k_2 son constantes empíricas. La figura 2 muestra la interfaz zona de transición (ITZ) que influye en la resistencia.

Figura 2

Representación esquemática de la zona de transición interfacial (ITZ).



Nota. Basado en ACI 211.1.

1.3.1 Variables que afectan la resistencia

Tabla 1
Variables de entrada y salida para el modelamiento de la red neuronal artificial

Tipo	Símbolo	Descripción
Datos de entrada	E1	Tamaño máximo nominal (pulg)
	E2	Módulo de finura del agregado fino
	E3	Módulo de finura del agregado grueso
	E4	Peso unitario suelto del agregado fino (kg/m^3)
	E5	Peso unitario suelto del agregado grueso (kg/m^3)
	E6	Peso unitario compactado del agregado fino (kg/m^3)
	E7	Peso unitario compactado del agregado grueso (kg/m^3)
	E8	Peso específico del cemento
	E9	Peso específico de masa del agregado fino
	E10	Peso específico de masa del agregado grueso
	E11	Absorción del agregado fino (%)
	E12	Absorción del agregado grueso (%)
	E13	Contenido de humedad del agregado fino (%)
	E14	Contenido de humedad del agregado grueso (%)
	E15	Relación agua/cemento de diseño
	E16	Edad de ensayo (días)
	E17	Resistencia de diseño (kg/cm^2)
	E18	Cemento (kg/m^3)
	E19	Agregado fino (kg/m^3)
	E20	Agregado grueso (kg/m^3)
	E21	Agua (L/m^3)
Dato de salida	S1	Resistencia a compresión de la probeta (kg/cm^2)

Nota. Basado en ACI 211.1.

1.4 Resistencia a compresión del concreto - ACI 211.1

1.4.1 Concreto hidráulico

El concreto hidráulico es un material compuesto formado por cemento, agua, agregados finos, agregados gruesos, aire y, en algunos casos, aditivos químicos o materiales cementantes suplementarios. Su comportamiento depende de la interacción física y química entre sus componentes. La pasta de cemento hidratada actúa como matriz aglomerante, mientras que los agregados conforman el esqueleto granular que aporta volumen, rigidez y estabilidad

dimensional (Mehta & Monteiro, 2014).

Desde el punto de vista tecnológico, el concreto debe satisfacer simultáneamente requisitos en estado fresco y endurecido. En estado fresco debe presentar trabajabilidad suficiente para ser mezclado, transportado, colocado, compactado y acabado sin segregación ni exudación excesiva. En estado endurecido debe alcanzar resistencia, rigidez, durabilidad y estabilidad volumétrica. El método ACI 211.1 toma en cuenta estos requisitos al seleccionar proporciones iniciales y ajustar la mezcla con base en ensayos de laboratorio (American Concrete Institute, 2009).

1.4.2 Componentes del concreto

1.4.2.1 Cemento Portland

El cemento Portland es un material hidráulico finamente molido que, al reaccionar con el agua, produce productos de hidratación capaces de desarrollar resistencia mecánica. Sus principales compuestos son silicato tricálcico, silicato dicálcico, aluminato tricálcico y aluminoferrito tetracálcico. La hidratación genera gel de silicato de calcio hidratado, hidróxido de calcio y otros productos secundarios que determinan la resistencia inicial y final del concreto (Mehta & Monteiro, 2014).

1.4.2.2 Agregados

Los agregados constituyen la mayor parte del volumen del concreto. Su granulometría, forma, textura, absorción, humedad, peso específico y módulo de finura influyen directamente en la trabajabilidad, demanda de agua, contenido de pasta y resistencia final. El agregado grueso controla la estructura resistente de la mezcla, mientras que el agregado fino mejora la cohesión y llena los vacíos entre partículas de mayor tamaño (ASTM International, 2023a).

1.4.2.3 Agua de mezclado

El agua cumple dos funciones principales: participa en la hidratación del cemento y proporciona fluidez a la mezcla. Sin embargo, el exceso de agua incrementa la porosidad capilar de la pasta endurecida y reduce la resistencia a compresión. Por esta razón, la relación agua-cemento es uno de los parámetros más importantes del diseño de mezclas (Neville, 2011).

1.4.2.4 Aditivos químicos

Los aditivos permiten modificar propiedades del concreto fresco o endurecido. Los plastificantes y superplastificantes reducen la demanda de agua; los incorporadores de aire mejoran la durabilidad frente a ciclos de congelamiento y deshielo; los retardantes y acelerantes controlan el tiempo de fraguado. En el método ACI 211.1, los aditivos deben considerarse en los

ajustes de agua, aire y volumen absoluto (American Concrete Institute, 2009).

1.4.3 Propiedades del concreto fresco

1.4.3.1 Trabajabilidad

La trabajabilidad representa la facilidad con la cual el concreto puede ser mezclado, colocado y compactado. No depende únicamente del asentamiento, sino también de la cohesión, plasticidad y resistencia a la segregación. Una mezcla con buena trabajabilidad no necesariamente posee alta resistencia; por el contrario, una trabajabilidad obtenida mediante exceso de agua puede perjudicar la resistencia final.

1.4.3.2 Asentamiento

El asentamiento se evalúa usualmente mediante el cono de Abrams. Este ensayo proporciona una medida indirecta de la consistencia del concreto fresco y se emplea como criterio de control de calidad en obra y laboratorio (ASTM International, 2020).

Tabla 2
Rangos usuales de asentamiento según tipo de elemento estructural

Elemento estructural	Mínimo (mm)	Máximo (mm)
Zapatas, losas de cimentación y muros masivos	25	75
Vigas y muros reforzados	25	100
Columnas estructurales	25	100
Pavimentos y losas	25	75
Concreto bombeado o de alta congestión de acero	75	150

Nota. Basado en ACI 211.1.

1.4.4 Resistencia a compresión del concreto

La resistencia a compresión es la propiedad mecánica más utilizada para evaluar la calidad del concreto, debido a que se relaciona con la capacidad portante de los elementos estructurales y con el desarrollo de la matriz cementante. Se determina mediante la carga máxima soportada por una probeta cilíndrica o cúbica dividida entre el área de aplicación de la carga (ASTM International, 2023b).

$$f'_c = \frac{P}{A} \quad (1.2)$$

donde f'_c es la resistencia a compresión, P es la carga máxima aplicada y A es el área transversal resistente. En probetas cilíndricas de diámetro d , el área se obtiene mediante:

$$A = \frac{\pi d^2}{4} \quad (1.3)$$

La resistencia a compresión depende de la relación agua-cemento, edad de ensayo, tipo de cemento, condiciones de curado, compactación, granulometría, calidad de agregados y presencia de aditivos. Para una misma mezcla, el curado húmedo adecuado permite mayor hidratación y menor porosidad, lo que incrementa la resistencia final (Mehta & Monteiro, 2014).

1.4.5 Ley de Abrams y relación agua-cemento


La ley de Abrams establece que, para materiales y condiciones de curado similares, la resistencia del concreto disminuye cuando aumenta la relación agua-cemento. Esta relación se explica por el incremento de vacíos capilares en la pasta endurecida cuando existe exceso de agua libre.

$$f'_c = \frac{K_1}{K_2^{(a/c)}} \quad (1.4)$$

donde K_1 y K_2 son constantes experimentales y a/c es la relación agua-cemento. Aunque la ecuación es empírica, su fundamento físico está asociado a la porosidad de la pasta y a la conectividad de los poros capilares (Neville, 2011).

Figura 3

Relación conceptual entre agua-cemento y resistencia a compresión



Nota. Basado en ACI 211.1.


1.4.6 Método ACI 211.1

El método ACI 211.1 proporciona un procedimiento para seleccionar proporciones de concreto normal, pesado y masivo. El procedimiento considera requisitos de consistencia,

resistencia, durabilidad y características de los agregados. Se basa en la estimación inicial de agua, contenido de aire, relación agua-cemento, cemento, agregado grueso, agregado fino y ajustes por humedad (American Concrete Institute, 2009). La fuente oficial de ACI describe que el procedimiento toma en cuenta requisitos de colocabilidad, consistencia, resistencia y durabilidad, además de ajustes según lotes de prueba.

1.4.7 Etapas del método ACI 211.1

Figura 4
Secuencia general del método ACI 211.1



Nota. Basado en el método ACI.

1.4.7.1 Resistencia promedio requerida

El diseño no se realiza únicamente para la resistencia especificada, sino para una resistencia promedio requerida que incorpora la variabilidad del proceso de producción. Cuando se dispone de desviación estándar, puede estimarse como:

$$f'_{cr} = f'_c + 1,34s \quad (1.5)$$

$$f'_{cr} = f'_c + 2,33s - 3,45 \quad (1.6)$$

donde f'_{cr} es la resistencia promedio requerida, f'_c es la resistencia especificada y s es la desviación estándar. Se adopta el valor mayor cuando corresponde, de acuerdo con criterios de control de calidad del concreto (Kosmatka & Wilson, 2016).

1.4.7.2 Contenido de cemento

Una vez seleccionados el contenido de agua y la relación agua-cemento, el contenido de cemento se calcula mediante:

$$C = \frac{W}{a/c} \quad (1.7)$$

donde C es el contenido de cemento en kg/m^3 , W es el contenido de agua en kg/m^3 y a/c es la relación agua-cemento. Si existen requisitos de durabilidad, se adopta la menor relación agua-cemento permitida y el mayor contenido mínimo de cemento requerido.

1.4.7.3 Volumen absoluto

El método de volumen absoluto se fundamenta en que la suma de los volúmenes absolutos de los componentes debe ser igual a un metro cúbico de concreto.

$$1 = V_c + V_w + V_{ag} + V_{af} + V_a + V_{ad} \quad (1.8)$$

El volumen de cada material se calcula como:

$$V_i = \frac{M_i}{G_i \gamma_w} \quad (1.9)$$

donde M_i es la masa del material, G_i es la gravedad específica y γ_w es el peso unitario del agua.

1.4.7.4 Corrección por humedad de agregados

Los agregados pueden encontrarse secos, saturados superficialmente secos o húmedos. El contenido de humedad modifica la cantidad real de agua aportada a la mezcla. Por tanto, el peso húmedo del agregado se obtiene mediante:

$$M_h = M_{ss}(1 + H) \quad (1.10)$$

El agua efectiva debe corregirse restando el agua libre aportada por los agregados:

$$W_{corr} = W_{diseño} - \sum M_{ss}(H - A_b) \quad (1.11)$$

donde H es la humedad total y A_b es la absorción del agregado.

Tabla 3
Variables principales del diseño de mezclas ACI 211.1

Variable	Descripción	Unidad
f'_c	Resistencia especificada de diseño	MPa
f'_{cr}	Resistencia promedio requerida	MPa
s	Desviación estándar del control de calidad	MPa
a/c	Relación entre masa de agua y masa de cemento	–
W	Agua de mezclado por metro cúbico	kg/m ³
C	Cemento por metro cúbico	kg/m ³
G_c	Gravedad específica del cemento	–
G_{ag}	Gravedad específica del agregado grueso	–
G_{af}	Gravedad específica del agregado fino	–
V_a	Volumen de aire	m ³

Nota. Elaboración propia, basada en el procedimiento de diseño de mezclas establecido por la norma ACI 211.1.

Tabla 4
Símbolos utilizados en el marco teórico del concreto

Símbolo	Significado
f'_c	Resistencia especificada a compresión del concreto.
f'_{cr}	Resistencia promedio requerida para compensar variabilidad.
P	Carga máxima aplicada durante el ensayo de compresión.
A	Área transversal de la probeta.
d	Diámetro de probeta cilíndrica.
a/c	Relación agua-cemento.
W	Contenido de agua de mezclado.
C	Contenido de cemento.
V_c	Volumen absoluto del cemento.
V_w	Volumen absoluto del agua.
V_{ag}	Volumen absoluto del agregado grueso.
V_{af}	Volumen absoluto del agregado fino.
V_a	Volumen de aire.

Símbolo	Significado
M_h	Masa húmeda del agregado.
M_{ss}	Masa del agregado en condición saturada superficialmente seca.
H	Humedad total del agregado.
A_b	Absorción del agregado.
G_i	Gravedad específica del material i .
γ_w	Peso unitario del agua.
s	Desviación estándar de resultados de resistencia.


Nota. Elaboración propia, basada en la terminología y simbología técnica del método de diseño de mezclas ACI 211.1.

1.4.8 Ensayo de resistencia a compresión

El ensayo ASTM C39/C39M cubre la determinación de la resistencia a compresión de especímenes cilíndricos moldeados o núcleos extraídos. El resultado se utiliza para control de calidad, aceptación del concreto, evaluación de proporciones y verificación de desempeño de aditivos (ASTM International, 2023b). La resistencia medida depende de la preparación, curado, refrentado, alineación de la máquina, velocidad de carga y geometría de la probeta.

Figura 5

Esquema de probeta cilíndrica sometida a compresión axial



Nota. basado en (ASTM International, 2023b).

1.4.9 Limitaciones del método ACI 211.1

El método ACI 211.1 es robusto para obtener una dosificación inicial, pero no reemplaza la verificación experimental. Sus tablas se basan en condiciones generales y pueden no re-

presentar exactamente los materiales locales. En Ayacucho, los agregados pueden presentar variaciones de absorción, humedad, forma, textura y granulometría, lo que obliga a realizar mezclas de prueba y correcciones sucesivas. Además, la relación entre dosificación y resistencia no siempre es lineal, especialmente cuando intervienen aditivos, cementos adicionados, edades distintas de ensayo y variaciones ambientales.

1.5 Redes neuronales artificiales para estimar F'_c

1.5.1 Inteligencia artificial y aprendizaje automático

La inteligencia artificial comprende métodos computacionales orientados a resolver tareas que requieren reconocimiento de patrones, predicción, clasificación, optimización y toma de decisiones. El aprendizaje automático es una rama de la inteligencia artificial que permite construir modelos a partir de datos, sin programar explícitamente todas las reglas del fenómeno (Bishop, 2006; Hastie et al., 2009). En ingeniería civil, estos modelos se emplean para predecir propiedades mecánicas, optimizar diseños, clasificar daños y estimar parámetros difíciles de obtener mediante modelos deterministas simples.

1.5.2 Redes neuronales artificiales

Las redes neuronales artificiales (RNA) son sistemas computacionales inspirados en el comportamiento de las neuronas biológicas, diseñados para aprender a partir de los datos y resolver problemas de diversa complejidad (Goodfellow et al., 2016). Están formadas por nodos o neuronas artificiales conectadas mediante pesos sinápticos. Cada neurona recibe entradas, calcula una combinación lineal ponderada, adiciona un sesgo y aplica una función de activación.

1.5.2.1 Analogía con la neurona biológica

Las RNA se desarrollaron a partir de una abstracción del comportamiento de las neuronas biológicas. Ambos sistemas comparten una estructura funcional semejante: reciben señales de entrada, procesan la información mediante conexiones ponderadas y generan una respuesta de salida. La Tabla 5 presenta la correspondencia entre los componentes de una neurona biológica y sus equivalentes en una neurona artificial.

Tabla 5
Analogía entre neurona biológica y neurona artificial

Neurona biológica	Neurona artificial
Dendritas (reciben señales de otras neuronas)	Entradas $(x_1, x_2, \dots, x_n)$
Sinapsis (conexiones que modulan la señal)	Pesos sinápticos $(w_1, w_2, \dots, w_n)$
Cuerpo celular o soma (integra las señales)	Regla de propagación $(\sum w_i x_i)$
Umbral de activación del potencial de acción	Función de activación $(g(\cdot))$
Axón (transmite la señal de salida)	Salida de la neurona (y)

Nota. Elaboración propia basada en Haykin (2009).

1.5.2.2 Modelo matemático de una neurona artificial

El funcionamiento de una neurona artificial se describe mediante las siguientes etapas:


1. **Conjunto de entradas:** Un vector de entrada $\mathbf{x} = [x_1, x_2, \dots, x_m]$.
2. **Pesos sinápticos:** Un vector de pesos $\mathbf{w} = [w_1, w_2, \dots, w_m]$, que representan la importancia de cada conexión.
3. **Regla de propagación:** Integra las entradas y los pesos mediante una sumatoria ponderada, a la que se añade un sesgo o umbral b :

$$z = \sum_{i=1}^m w_i x_i + b \quad (1.12)$$

4. **Función de activación:** Es una función no lineal $f(\cdot)$ que produce la salida de la neurona:

$$y = f(z) = f\left(\sum_{i=1}^m w_i x_i + b\right) \quad (1.13)$$

Figura 6
Modelo matemático de una neurona artificial



Nota. Elaboración propia, basada en el modelo de neurona artificial propuesto por Haykin (2009).

1.5.3 Funciones de activación

Las funciones de activación son cruciales porque introducen no linealidad en la red, permitiéndole aprender relaciones complejas. Sin ellas, una red con múltiples capas sería equivalente a una transformación lineal. Las funciones más comunes se resumen en la Tabla 6.

Tabla 6
Funciones de activación usadas en redes neuronales

Función	Ecuación	Uso frecuente
Sigmoide	$\sigma(x) = \frac{1}{1+e^{-x}}$	Clasificación binaria
Tangente hiperbólica	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	Capas ocultas centradas
ReLU	$ReLU(x) = \max(0, x)$	Capas ocultas profundas
Leaky ReLU	$f(x) = \max(\alpha x, x)$	Evitar neuronas muertas
Lineal	$f(x) = x$	Salida en regresión

Nota. Basado en las funciones de activación descritas por Goodfellow et al. (2016) y Haykin (2009).

1.5.4 Arquitectura de redes neuronales

Las redes neuronales pueden clasificarse según su arquitectura, la cual define el modo en que se conectan las neuronas entre sí.


1.5.4.1 Perceptrón multicapa (MLP)

El perceptrón multicapa es una red *feedforward* compuesta por una capa de entrada, una o más capas ocultas y una capa de salida. Las neuronas de una capa se conectan con todas las

neuronas de la capa siguiente, formando una red "totalmente conectada." densa. El flujo de información es unidireccional, desde la entrada hacia la salida (alimentación hacia adelante).

Para la predicción de resistencia a compresión, las entradas pueden ser cemento, agua, agregado fino, agregado grueso, edad, aditivos, relación agua-cemento, contenido de aire y propiedades físicas de agregados. La salida corresponde a la resistencia estimada $\hat{f}'_c$.

Figura 7
Arquitectura MLP para predicción de resistencia a compresión



Nota. Basado en la arquitectura de perceptrón multicapa (MLP) descrita por Haykin (2009) y Goodfellow et al. (2016).

1.5.4.2 Propagación hacia adelante

En una red neuronal, la propagación hacia adelante calcula la salida estimada a partir de las entradas. Para la capa l se tiene:

$$\mathbf{z}^{(l)} = \mathbf{W}^{(l)} \mathbf{a}^{(l-1)} + \mathbf{b}^{(l)} \quad (1.14)$$

$$\mathbf{a}^{(l)} = f(\mathbf{z}^{(l)}) \quad (1.15)$$

donde $\mathbf{W}^{(l)}$ es la matriz de pesos, $\mathbf{b}^{(l)}$ es el vector de sesgos y f es la función de activación.

1.5.5 Mecanismos de aprendizaje

El aprendizaje en las redes neuronales artificiales constituye el proceso mediante el cual la red ajusta sus parámetros internos, principalmente los pesos sinápticos, a partir de la información proporcionada por los datos de entrada. Este mecanismo permite que la red adquiera conocimiento y mejore su desempeño en una tarea específica (Matich, 2001).

1.5.5.1 Aprendizaje supervisado

El aprendizaje supervisado es el enfoque más utilizado en el entrenamiento de redes neuronales. El proceso se desarrolla a partir de un conjunto de datos previamente etiquetados, donde cada entrada se encuentra asociada a una salida deseada. Durante el entrenamiento, la red genera una predicción que se compara con el valor objetivo. A partir del error, se ajustan los pesos internos para minimizar dicho error y mejorar gradualmente la precisión de las predicciones futuras (Haykin, 2009).

1.5.5.2 Aprendizaje no supervisado

En el aprendizaje no supervisado, las redes neuronales modifican sus pesos sin la participación de una guía externa. La red no recibe retroalimentación acerca de si la salida es acertada o errónea. En algunos casos, la red lleva a cabo tareas de *clustering* o agrupamiento, donde su objetivo es identificar y asignar la entrada a una categoría particular, descubriendo patrones a partir de las correlaciones en los datos (Matich, 2001).

1.5.6 Entrenamiento y retropropagación

El entrenamiento consiste en ajustar pesos y sesgos para minimizar una función de pérdida. El algoritmo de retropropagación calcula gradientes de la pérdida respecto a cada parámetro, aplicando la regla de la cadena (Goodfellow et al., 2016).

$$\mathcal{L}(\theta) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1.16)$$

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} \mathcal{L}(\theta_t) \quad (1.17)$$

donde η es la tasa de aprendizaje. En aplicaciones modernas se emplean optimizadores adaptativos como Adam, que ajustan la tasa efectiva de aprendizaje usando momentos de primer y segundo orden del gradiente (Géron, 2022).

1.5.7 Métricas de evaluación

Para comparar el modelo ACI 211.1 y la red neuronal artificial, se recomienda emplear métricas de error y ajuste. Las más comunes son MAE, MSE, RMSE y R^2 .

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1.18)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1.19)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1.20)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1.21)$$

Tabla 7
Interpretación de métricas para predicción de resistencia del concreto

Métrica	Interpretación	Criterio deseable
MAE	Error absoluto promedio entre valor real y predicho	Menor valor
MSE	Penaliza con mayor intensidad errores grandes	Menor valor
RMSE	Error en las mismas unidades de la resistencia	Menor valor
R^2	Proporción de variabilidad explicada por el modelo	Cercano a 1

Nota. Métricas de evaluación de modelos de aprendizaje automático descritas por Goodfellow et al. (2016), Haykin (2009) y [geron2023](#)<empty citation>.

1.5.8 Variables de entrada para redes neuronales en concreto

Las variables de entrada deben seleccionarse de acuerdo con la teoría del concreto y con la disponibilidad de datos. Una red neuronal no debe entrenarse únicamente como caja negra; debe incorporar variables físicamente significativas. En predicción de resistencia, las variables más usuales son contenido de cemento, agua, agregados, aditivos, edad y relación agua-cemento (Chou et al., 2011).

Tabla 8
Variables recomendadas para una RNA aplicada al concreto

Variable	Justificación técnica	Unidad
Cemento	Aporta productos de hidratación y resistencia	kg/m ³
Agua	Controla fluidez y porosidad capilar	kg/m ³
Agregado fino	Modifica cohesión y demanda de pasta	kg/m ³
Agregado grueso	Define esqueleto granular resistente	kg/m ³
Aditivo	Reduce agua o modifica fraguado	kg/m ³
Edad	Representa avance de hidratación	días
Relación a/c	Indicador principal de porosidad	–
Asentamiento	Indicador de consistencia inicial	mm

Nota. Variables empleadas para la predicción de la resistencia a compresión del concreto mediante redes neuronales artificiales propuestas por Yeh (1998), Haykin (2009) y Goodfellow et al. (2016).

1.5.9 Normalización de datos

La normalización mejora la estabilidad numérica del entrenamiento. Las variables de entrada pueden presentar unidades y escalas diferentes; por ejemplo, la edad se expresa en días, el cemento en kg/m³ y la relación agua-cemento es adimensional. La normalización min-max se calcula como:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1.22)$$

La estandarización tipo puntuación z se calcula como:

$$z = \frac{x - \mu}{\sigma} \quad (1.23)$$


1.5.10 Sobreajuste y regularización

El sobreajuste ocurre cuando el modelo aprende patrones específicos del conjunto de entrenamiento y pierde capacidad de generalización. En una tesis experimental, esto puede conducir a resultados aparentemente excelentes en entrenamiento, pero deficientes al pre-

decir nuevas mezclas. Para reducirlo se emplean división entrenamiento-validación-prueba, regularización L_2 , dropout y parada temprana (Géron, 2022).

$$\mathcal{L}_{reg} = \mathcal{L} + \lambda \sum_{j=1}^p w_j^2 \quad (1.24)$$

Figura 8
Curvas conceptuales de pérdida y posible sobreajuste



Nota. Basado en (Géron, 2022).

1.5.11 Aplicación de RNA a la resistencia del concreto

El uso de redes neuronales para predecir resistencia del concreto se consolidó desde trabajos pioneros como el de Yeh (1998), quien modeló la resistencia de concreto de alto desempeño mediante redes neuronales. Estudios posteriores compararon redes neuronales con técnicas de minería de datos, lógica difusa y modelos estadísticos, mostrando que los métodos de aprendizaje automático pueden capturar relaciones no lineales entre dosificación, edad y resistencia (Chou et al., 2011). Investigaciones recientes han continuado aplicando redes neuronales y aprendizaje profundo para estimar resistencia y durabilidad, con bases de datos más amplias y modelos de mayor capacidad (Hosseinzadeh et al., 2024b).

En la presente investigación, el modelo de RNA no debe interpretarse como sustituto absoluto del criterio técnico, sino como herramienta de predicción basada en datos. Su utilidad depende de la calidad de los ensayos, representatividad de las mezclas, control de variables, tamaño de muestra y validación estadística. Si el conjunto de datos local de Ayacucho incluye variaciones reales de agregados, humedad, relación agua-cemento y edad, la RNA puede aprender patrones específicos que el método ACI 211.1 no representa directamente.

Tabla 9
Comparación conceptual entre método ACI 211.1 y RNA

Criterio	Método ACI 211.1	Red neuronal artificial
Naturaleza	Procedimiento normativo empírico	Modelo computacional basado en datos
Entrada	Parámetros de diseño y propiedades de agregados	Variables experimentales y dosificación
Salida	Proporciones iniciales de mezcla	Resistencia estimada o dosificación optimizada
Ventaja	Fácil aplicación y respaldo técnico	Captura relaciones no lineales complejas
Limitación	Requiere ajustes por materiales locales	Requiere base de datos suficiente y validación
Uso recomendado	Diseño inicial y control de mezcla	Predicción, comparación y optimización

Nota. Basado en el método de diseño de mezclas ACI 211.1.

1.6 Integración teórica para la investigación


La comparación entre ACI 211.1 y redes neuronales artificiales debe plantearse como contraste entre un método normativo de dosificación y un modelo predictivo calibrado con datos. El método ACI 211.1 permite determinar proporciones iniciales racionales; posteriormente, los ensayos de resistencia generan una base de datos que puede ser utilizada para entrenar una RNA. El desempeño de ambos enfoques puede evaluarse mediante errores absolutos, errores cuadráticos y coeficiente de determinación.

Desde el punto de vista metodológico, la variable dependiente es la resistencia a compresión del concreto, mientras que las variables independientes incluyen los contenidos de cemento, agua, agregados, aditivos, relación agua-cemento, edad, asentamiento y propiedades físicas de los agregados. La comparación será válida si ambos enfoques se evalúan con el mismo conjunto de mezclas y bajo condiciones controladas de fabricación, curado y ensayo.

Se anticipa que las RNA superen al método ACI en precisión debido a su capacidad para capturar interacciones no lineales con materiales locales (canteras de Ayacucho). La figura 9 muestra el modelo conceptual de comparación.

Figura 9

Modelo conceptual de comparación entre ACI 211.1 y RNA



Nota. Basado en Yeh (1998), Haykin (2009) y Goodfellow et al. (2016).

Capítulo 2

METODOLOGÍA

2.1 Ubicación

2.1.1 Ubicación política

La investigación se encuentra ubicado en:

- **País:** Perú.
- **Departamentos:** Ayacucho.
- **Provincias:** Huamanga.
- **Distrito:** Ayacucho.

2.1.2 Ubicación geográfica


El Distrito de Ayacucho, capital de la Provincia de Huamanga en la región Ayacucho, se localiza en la sierra sur del Perú, dentro de un valle interandino a una altitud aproximada de 2,700 m s.n.m. Geográficamente, se sitúa en el sistema de coordenadas UTM, zona 18 Sur, con coordenadas aproximadas de 584,000 m E y 8,539,000 m N, lo que permite su precisa ubicación cartográfica. Este distrito constituye el núcleo urbano, administrativo y económico más importante de la región, y se encuentra rodeado por distritos como San Juan Bautista, Carmen Alto y Jesús Nazareno.

El Distrito de Ayacucho, en la Provincia de Huamanga, presenta una dinámica económica y social basada principalmente en el comercio, los servicios y la actividad pública, al ser capital regional. Las actividades económicas más relevantes incluyen el comercio minorista y mayorista, el turismo especialmente durante la Semana Santa de Ayacucho—, la artesanía tradicional (retablos, textiles y cerámica), así como la educación y salud, que generan empleo en instituciones públicas y privadas. En el ámbito social, el distrito se caracteriza por una población con fuerte identidad cultural andina, presencia de instituciones educativas y centros de salud, y una activa vida comunitaria vinculada a festividades religiosas, mercados locales

y organizaciones vecinales, aunque también enfrenta desafíos como el crecimiento urbano, la informalidad y la necesidad de mejorar servicios básicos e infraestructura.

A continuación se muestra la mapa de ubicación en coordenadas geográficas para determinar la ubicación de Ayacucho.

Figura 10
Área de estudio



Nota. Elaboración propia.

2.2 Vías de acceso

El desarrollo de la presente investigación se llevó a cabo en la ciudad de Ayacucho, provincia de Huamanga, departamento de Ayacucho. El acceso a la ciudad se realiza principalmente por vía terrestre a través de la Carretera Longitudinal de la Sierra (PE-3S), que conecta Ayacucho con las ciudades de Huancayo, Andahuaylas, Abancay y Lima, permitiendo el transporte continuo de personas, equipos y materiales. Asimismo, la ciudad cuenta con el Aeropuerto Coronel FAP Alfredo Mendívil Duarte, que brinda vuelos comerciales regulares desde Lima, facilitando el acceso por vía aérea.

2.3 Características climáticas

El desarrollo de la investigación se realizó en la ciudad de Ayacucho, provincia de Huamanga, departamento de Ayacucho, ubicada en la región sur-central del Perú, a una altitud aproximada de 2 746 m s. n. m. El clima de la ciudad es templado y seco, característico de la sierra peruana, con una temperatura media anual que oscila entre 15 °C y 17 °C. Durante el día se registran temperaturas relativamente cálidas, mientras que durante la noche son frecuentes descensos significativos de temperatura debido a la elevada altitud.

El régimen de precipitaciones presenta dos estaciones bien definidas: una temporada de lluvias, comprendida generalmente entre los meses de noviembre y abril, y una temporada seca, entre mayo y octubre, caracterizada por escasas precipitaciones, baja humedad relativa y elevada radiación solar. La precipitación anual promedio se encuentra entre 500 y 700 mm, concentrándose la mayor parte durante la época lluviosa.

Las condiciones climáticas de Ayacucho influyen en el comportamiento del concreto, especialmente durante las etapas de elaboración, fraguado y curado. Las bajas temperaturas nocturnas y la reducida humedad relativa durante la estación seca pueden incrementar la velocidad de evaporación del agua de mezclado, afectando el desarrollo de la resistencia si no se aplican procedimientos adecuados de curado. Por ello, durante la ejecución de los ensayos se controlaron las condiciones de preparación, conservación y curado de las probetas conforme a las recomendaciones de las normas técnicas vigentes, con el fin de minimizar la influencia de los factores ambientales sobre los resultados obtenidos.

Estas características climáticas proporcionan un entorno representativo para evaluar y comparar la resistencia a compresión del concreto obtenida mediante el método tradicional de diseño de mezclas ACI 211.1 y la estimada mediante redes neuronales artificiales, asegurando que las diferencias observadas se deban principalmente a los métodos de estimación y no a variaciones ambientales.

2.4 Metodología

2.4.1 Tipo de investigación

Según Hernández Sampieri et al. (2014), Se considera que este tipo de investigación aplicada se define como Condiciones reguladas en las que se altera intencionalmente una o más variables independientes (factores causales) para examinar el impacto de estos cambios en una o más variables dependientes (efectos)” (p.130). La investigación es aplicada; ya que, se aplicarán criterios técnicos para el análisis de materiales, la modelación computacional del diseño de mezclas, la validación estructural mediante cálculos precisos y el uso de tecnologías innovadoras como las redes neuronales, con el objetivo de generar soluciones sostenibles y de impacto positivo para la infraestructura en Ayacucho.

2.4.2 Nivel de investigación

Según Hernández Sampieri et al. (2014), la presente investigación es de nivel **predictivo**, debido a que busca estimar la resistencia a compresión del concreto mediante un modelo de red neuronal artificial. Para ello, se emplean como variables de entrada las características de los materiales, propiedades de los agregados, dosificación y edad de ensayo. El modelo es entrenado con datos históricos para identificar las relaciones entre dichas variables y la resistencia observada. Posteriormente, su capacidad predictiva se evalúa mediante los indicadores MSE, MAE, RMSE y R^2 , comparando los valores reales con los valores estimados por el modelo.

2.4.3 diseño de investigación

Según Hernández Sampieri et al. (2014), el diseño de la investigación va tener un componente experimental porque va caracterizar, dosificar, fabricar y realizar ensayo de concreto para colaborar los resultados de la red neuronal artificial y también va tener un componente computacional porque va entrenar, validar y realizar la prueba para el modelo de RNA.

2.4.4 Población, muestra y técnicas de muestreo

2.4.4.1 Población

Según Hernández Sampieri et al. (2014), La población está constituida por las probetas o resultados de resistencia a compresión correspondientes al concreto utilizado en la edificación de la Escuela Profesional de Ingeniería Agrícola. De este conjunto se contó con un total de 806 resultados de roturas de concreto, los cuales constituyeron la muestra utilizada para alimentar y entrenar la red neuronal artificial. En esta investigación se ha considerado la información correspondiente a la construcción de la Escuela Profesional de Ingeniería Agrícola, donde se trabajó con agregados provenientes de la cantera chillico. Por lo tanto, los datos de

las 806 probetas fueron utilizados como información histórica para que la red neuronal artificial pudiera identificar la relación existente entre las características de los materiales, la dosificación del concreto y la resistencia obtenida.

2.4.4.2 Muestra

Según Hernández Sampieri et al. (2014), La muestra estuvo constituida por la totalidad de los 806 resultados de ensayos de resistencia a compresión del concreto correspondientes a la construcción de la Escuela Profesional de Ingeniería Agrícola. Debido a que se empleó la totalidad de los registros disponibles que conforman la población de estudio, se consideró una muestra censal, por lo que el tamaño de la muestra fue de $n = 806$ resultados.

Estos registros fueron utilizados como datos históricos para el desarrollo del modelo de red neuronal artificial, permitiendo identificar la relación entre las características de los materiales, la dosificación del concreto y la resistencia a compresión obtenida.

2.4.5 Técnicas e instrumentos

2.4.5.1 Técnicas

Para el desarrollo de la presente investigación se emplearon las siguientes técnicas:

1. Recolección de muestras *in situ*

- Extracción directa de agregados finos y gruesos en la cantera de Chillico Huaycco.
- Recolección del agua utilizada para la elaboración de las mezclas de concreto.

2. Observación directa y ensayos de laboratorio

- Observación del comportamiento del concreto en estado fresco y endurecido.
- Ejecución de ensayos normalizados de acuerdo con las Normas Técnicas Peruanas (NTP) y las normas ASTM vigentes.

3. Experimentación controlada

- Diseño y elaboración de mezclas mediante el método ACI 211.1.
- Registro de las propiedades del concreto, tales como resistencia a la compresión, asentamiento (slump), trabajabilidad y relación agua-cemento.

4. Modelado mediante redes neuronales artificiales

- Implementación de un modelo basado en Redes Neuronales Artificiales (RNA) para estimar la resistencia a compresión del concreto.
- Optimización de las proporciones de mezcla y análisis de la relación entre las variables de entrada y la resistencia obtenida.

5. Análisis documental

- Revisión de investigaciones científicas, normas técnicas y bibliografía especializada relacionada con el diseño de mezclas de concreto y la aplicación de inteligencia artificial.

2.4.5.2 Instrumentos

Los instrumentos utilizados para la recolección y procesamiento de la información fueron los siguientes:

1. Equipos de laboratorio de concreto

- Balanza de precisión para el pesaje de cemento y agregados.
- Juego de tamices para el análisis granulométrico.
- Cono de Abrams para determinar el asentamiento del concreto.
- Moldes cilíndricos normalizados para la elaboración de probetas.
- Prensa hidráulica para los ensayos de resistencia a la compresión.
- Tanques o cámaras de curado para la conservación de las probetas.

2. Software y herramientas informáticas

- Microsoft Excel para el registro y organización de datos.
- Python para el procesamiento de datos y entrenamiento de la Red Neuronal Artificial.
- TensorFlow y Keras para la implementación, entrenamiento y validación del modelo predictivo.

3. Formatos de laboratorio

- Fichas de registro para las proporciones de mezcla.
- Formatos para el control de asentamiento, peso unitario y resistencia a la compresión.
- Hojas de control del proceso de curado y edades de ensayo.

4. Equipo de registro fotográfico

- Cámara digital o teléfono celular con GPS para documentar la extracción de materiales, elaboración de mezclas y ejecución de ensayos.

2.4.5.3 Técnicas de procesamiento y análisis de datos

Codificación y tabulación de datos Los datos experimentales obtenidos durante la investigación fueron organizados, codificados y procesados mediante herramientas informáticas, siguiendo el procedimiento descrito a continuación:

- Registro y organización de la información en hojas de cálculo de Microsoft Excel.
- Depuración y verificación de la consistencia de los datos experimentales.
- Codificación de las variables de entrada y salida utilizadas en el modelo de Redes Neuronales Artificiales.
- Procesamiento estadístico y análisis exploratorio de los datos mediante Python.
- Elaboración de tablas, gráficos y matrices para la comparación de resultados entre el método ACI 211.1 y las Redes Neuronales Artificiales.

Las principales variables codificadas fueron:

- Tipo de agregado.
- Contenido de cemento.
- Contenido de agua.
- Cantidad de agregado fino.
- Cantidad de agregado grueso.
- Relación agua/cemento.
- Asentamiento (*slump*).
- Edad del concreto (7, 14 y 28 días).
- Resistencia a la compresión (kg/cm^2 o MPa).

2.4.5.4 Ética y permisos

La presente investigación se desarrolló respetando los principios éticos de integridad científica, objetividad, honestidad, transparencia y responsabilidad durante todas las etapas del proceso investigativo. Los ensayos de laboratorio, el procesamiento de datos y la comparación entre el método de diseño de mezclas ACI 211.1 y las Redes Neuronales Artificiales (RNA) fueron ejecutados sin alterar ni manipular los resultados obtenidos, garantizando la veracidad y confiabilidad de la información.

Asimismo, se respetó la propiedad intelectual mediante la adecuada citación de las fuentes bibliográficas, normas técnicas y documentos científicos consultados, siguiendo las normas de citación establecidas por la American Psychological Association (APA, séptima edición). Los datos obtenidos fueron utilizados exclusivamente con fines académicos y de investigación, preservando la confidencialidad de la información cuando correspondió.

Debido a que la investigación corresponde a un estudio experimental sobre materiales de construcción y no involucra la participación de seres humanos ni animales de experimentación, no existieron riesgos éticos relacionados con la salud, la integridad física o la privacidad de las personas.

Para la ejecución de la investigación se gestionó la autorización del laboratorio de tecnología del concreto donde se realizaron la caracterización de los agregados, el diseño de mezclas, la elaboración, el curado y los ensayos de resistencia a la compresión de las probetas. Asimismo, se contó con la autorización para la extracción y utilización de los agregados provenientes de la cantera Chillico Huaycco, empleándose únicamente para fines de investigación.

El uso de los equipos de laboratorio, materiales, instalaciones y software especializado se realizó conforme a los procedimientos y normas establecidos por la institución donde se desarrolló la investigación, garantizando el adecuado manejo de los recursos y el cumplimiento de las Normas Técnicas Peruanas (NTP), las normas ASTM aplicables y las recomendaciones del American Concrete Institute (ACI 211.1).

2.5 Materiales y equipos

Para la ejecución de la presente investigación se utilizaron materiales para la elaboración de las mezclas de concreto, equipos de laboratorio para la caracterización de los agregados y el ensayo de las probetas, así como herramientas informáticas para el procesamiento de los datos y la implementación de las redes neuronales artificiales.

Materiales

- Cemento Portland tipo I.
- Agregado fino procedente de la cantera Chillico Huaycco.
- Agregado grueso procedente de la cantera Chillico Huaycco.
- Agua potable para la elaboración y curado de las mezclas.
- Aditivo para concreto, en caso de ser considerado en el diseño.
- Desmoldante para los moldes cilíndricos.
- Bolsas y recipientes para el almacenamiento de muestras.
- Etiquetas y marcadores permanentes para la identificación de probetas.

- Guantes, mascarillas y materiales de limpieza.

Equipos de laboratorio

- Balanza de precisión.
- Juego de tamices granulométricos.
- Horno de secado.
- Recipientes para determinar el peso unitario de los agregados.
- Picnómetro o canastilla para determinar el peso específico y la absorción.
- Mezcladora de concreto.
- Cono de Abrams.
- Varilla compactadora.
- Bandejas metálicas.
- Palas, cucharones y carretilla.
- Moldes cilíndricos de 15 cm de diámetro por 30 cm de altura.
- Martillo de goma.
- Tanque o poza de curado.
- Prensa hidráulica para el ensayo de resistencia a compresión.
- Vernier o regla metálica para la verificación dimensional de las probetas.
- Cronómetro y termómetro.

Equipos informáticos

- Computadora portátil o de escritorio.
- Microsoft Excel para el registro y organización de datos.
- Python para el procesamiento de datos.
- TensorFlow y Keras para el entrenamiento de la red neuronal artificial.
- SPSS, MATLAB u otro programa estadístico para el análisis de resultados.
- Cámara fotográfica o teléfono celular para el registro de las actividades.

2.6 Desarrollo de la investigación

2.6.1 Variables de entrada y salida de la red neuronal artificial

La red neuronal artificial desarrollada en la presente investigación utiliza como información de entrada las propiedades físicas de los agregados, las características de la dosificación, la edad de ensayo y las cantidades de materiales que conforman un metro cúbico de concreto. La única variable de salida corresponde a la resistencia a compresión experimental obtenida de los testigos de concreto.

En total, el modelo utiliza veintiún parámetros de entrada y una variable de salida. El vector de entrada correspondiente a la observación i se representa mediante:

$$\begin{aligned} \mathbf{x}_i = [& TMN_i, MF_{AF,i}, MF_{AG,i}, PUS_{AF,i}, PUS_{AG,i}, \\ & PUC_{AF,i}, PUC_{AG,i}, PEC_i, PE_{AF,i}, PE_{AG,i}, \\ & Abs_{AF,i}, Abs_{AG,i}, CH_{AF,i}, CH_{AG,i}, \\ & (a/c)_i, t_i, f'_{c,d,i}, C_i, AF_i, AG_i, W_i] \end{aligned} \quad (2.1)$$

donde cada término representa una característica física, una condición de diseño o una cantidad de material correspondiente a la mezcla de concreto.

La variable de salida se expresa como:

$$y_i = f'_{c,\text{exp},i} \quad (2.2)$$

donde $f'_{c,\text{exp}}$ es la resistencia a compresión experimental obtenida mediante el ensayo de los testigos de concreto.

Tabla 10
Parámetros de entrada y variable de salida de la red neuronal

Tipo	Parámetro	Símbolo	Unidad	Descripción
Entrada	Tamaño máximo nominal del agregado	TMN	pulg	Tamaño máximo nominal empleado en la mezcla.
Entrada	Módulo de finura del agregado fino	MF_{AF}	–	Caracteriza la granulometría del agregado fino.
Entrada	Módulo de finura del agregado grueso	MF_{AG}	–	Caracteriza la granulometría del agregado grueso.
Entrada	Peso unitario suelto del agregado fino	PUS_{AF}	kg/m ³	Peso volumétrico del agregado fino en estado suelto.
Entrada	Peso unitario suelto del agregado grueso	PUS_{AG}	kg/m ³	Peso volumétrico del agregado grueso en estado suelto.
Entrada	Peso unitario compactado del agregado fino	PUC_{AF}	kg/m ³	Peso volumétrico compactado del agregado fino.
Entrada	Peso unitario compactado del agregado grueso	PUC_{AG}	kg/m ³	Peso volumétrico compactado del agregado grueso.
Entrada	Peso específico del cemento	PE_C	–	Propiedad física del cemento empleado.
Entrada	Peso específico de masa del agregado fino	PE_{AF}	–	Propiedad física del agregado fino.
Entrada	Peso específico de masa del agregado grueso	PE_{AG}	–	Propiedad física del agregado grueso.
Entrada	Absorción del agregado fino	Abs_{AF}	%	Porcentaje de absorción del agregado fino.
Entrada	Absorción del agregado grueso	Abs_{AG}	%	Porcentaje de absorción del agregado grueso.
Entrada	Contenido de humedad del agregado fino	CH_{AF}	%	Contenido de humedad registrado en el agregado fino.
Entrada	Contenido de humedad del agregado grueso	CH_{AG}	%	Contenido de humedad registrado en el agregado grueso.
Entrada	Relación agua-cemento de diseño	a/c	–	Relación entre el contenido de agua y cemento.
Entrada	Edad de ensayo	t	días	Edad del concreto al momento del ensayo.
Entrada	Resistencia de diseño	$f'_{c,d}$	kg/cm ²	Resistencia especificada para el diseño de la mezcla.
Entrada	Cantidad de cemento	C	kg/m ³	Cantidad de cemento por metro cúbico de concreto.
Entrada	Cantidad de agregado fino	AF	kg/m ³	Cantidad de agregado fino por metro cúbico de concreto.
Entrada	Cantidad de agregado grueso	AG	kg/m ³	Cantidad de agregado grueso por metro cúbico de concreto.
Entrada	Cantidad de agua	W	L/m ³	Cantidad de agua por metro cúbico de concreto.
Salida	Resistencia a compresión del testigo	$f'_{c,exp}$	kg/cm²	Resistencia experimental pre-dicha por la red neuronal.

Nota. Baasado en Hernandez Sampieri.

2.6.2 Rango de trabajabilidad y volumen de entrada y salida

Para el concreto con resistencia de diseño $f'_c = 210 \text{ kg/cm}^2$, se registró una relación agua–cemento de 0,56, un contenido de agua de $187,81 \text{ L/m}^3$, un contenido de cemento de $366,07 \text{ kg/m}^3$ y un tamaño máximo nominal del agregado de $0,75''$. A partir de estas características se estimó una consistencia plástica y una trabajabilidad media, correspondiente a un asentamiento aproximado comprendido entre 75 y 100 mm.

$$75 \text{ mm} \leq \text{Asentamiento} \leq 100 \text{ mm} \quad (2.3)$$

Expresado en pulgadas:

$$3'' \leq \text{Slump} \leq 4'' \quad (2.4)$$

Debe precisarse que este rango representa un valor estimado a partir de las características de la dosificación, debido a que la base de datos no contiene resultados directos del ensayo de asentamiento.

Las cantidades de cemento, agregado fino, agregado grueso y agua se encuentran expresadas por metro cúbico de concreto. Por consiguiente, el volumen teórico de entrada considerado en cada diseño fue:

$$V_{\text{entrada}} = 1,00 \text{ m}^3 \quad (2.5)$$

Para dicho volumen se consideraron las siguientes cantidades:

Tabla 11
Materiales de entrada para el concreto $f'_c = 210 \text{ kg/cm}^2$

Material	Cantidad por metro cúbico
Cemento	$366,07 \text{ kg/m}^3$
Agregado fino	$775,75 \text{ kg/m}^3$
Agregado grueso	$954,33 \text{ kg/m}^3$
Agua	$187,81 \text{ L/m}^3$

Nota. Basado en el procedimiento de diseño de mezclas para concreto de resistencia $f'_c = 210 \text{ kg/cm}^2$ establecido por el método ACI 211.1.

Considerando un desperdicio aproximado del 10 % durante el mezclado, transporte, colocación y compactación, el volumen útil de salida se estimó mediante:

$$V_{\text{salida}} = V_{\text{entrada}} \left(1 - \frac{10}{100} \right) \quad (2.6)$$

$$V_{\text{salida}} = 1,00(0,90) \quad (2.7)$$

$$V_{\text{salida}} = 0,90 \text{ m}^3 \quad (2.8)$$

El volumen estimado de desperdicio fue:

$$V_{\text{desperdicio}} = V_{\text{entrada}} - V_{\text{salida}} \quad (2.9)$$

$$V_{\text{desperdicio}} = 0,10 \text{ m}^3 \quad (2.10)$$

2.6.3 Obtención de la dataset para el modelo RNA

Para la presente investigación se seleccionó la dataset para el entrenamiento, la validación y la prueba del modelo de red neuronal artificial (RNA), trabajando con 806 muestras de ensayos de rotura de concreto a la compresión obtenidos con material del río de Chillico Huaycco, cantera muy conocido en la región que abastece material de construcción a la mayoría de los proyectos, donde se cuenta con material acopiado para suministrar a los proyectos de la región.

Tabla 12
Parámetros de entrada y salida de la red neuronal artificial

Simbología	Datos de entrada
E1	Tamaño máximo nominal (pulg)
E2	Módulo de finura del agregado fino
E3	Módulo de finura del agregado grueso
E4	Peso unitario suelto del agregado fino (kg/m3)
E5	Peso unitario suelto del agregado grueso (kg/m3)
E6	Peso unitario compactado del agregado fino (kg/m3)
E7	Peso unitario compactado del agregado grueso (kg/m3)
E8	Peso específico del cemento
E9	Peso específico de masa del agregado fino
E10	Peso específico de masa del agregado grueso
E11	Absorción del agregado fino (%)
E12	Absorción del agregado grueso (%)
E13	Contenido de humedad del agregado fino(%)
E14	Contenido de humedad del agregado grueso(%)
E15	Relación agua cemento de diseño
E16	Edad de ensayo (días)

E17	Resistencia de diseño (kg/cm2)
E18	Cemento (Kg/m3)
E19	Agregado fino (kg/m3)
E20	Agregado grueso (kg/m3)
E21	agua (l/m3)
S1	Resistencia de probeta (kg/cm2)

Nota: Elaboración propia

2.6.4 Normalización de la dataset para el modelo RNA

Para el trabajo con las redes neuronales artificiales se necesita normalizar los datos utilizando las siguientes fórmulas de normalización de las diferentes funciones de activación que se utilizan en entrenamiento de las redes neuronales artificiales.

Para el entrenamiento de la red neuronal artificial, los datos de entrada fueron normalizados con el método Min–Max, con la finalidad de escalar las variables en un rango común y evitar que las variables con mayor magnitud dominen el proceso de aprendizaje. La normalización entre 0 y 1 se realizó mediante la siguiente expresión:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.11)$$

Asimismo, cuando se requiera trabajar en el intervalo de -1 a 1 , se emplea la siguiente transformación:

$$x' = 2 \left(\frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) - 1 \quad (2.12)$$

Donde x' representa el valor normalizado, x el valor original, $x_{\min}$ el valor mínimo de la variable y $x_{\max}$ el valor máximo de la variable.

Tabla 13
Datos de entrada normalizados entre 0 y 1: E1–E12

E1	E2	E3	E4	E5	E6	E7	E8	E9	E10	E11	E12
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449

Tabla 13
Datos de entrada normalizados entre 0 y 1: E1–E12 (continuación)

[illegible]

Tabla 13
Datos de entrada normalizados entre 0 y 1: E1–E12 (continuación)

E1	E2	E3	E4	E5	E6	E7	E8	E9	E10	E11	E12
0.250	0.305	0.505	0.913	0.568	1.000	0.730	1.000	0.412	0.450	0.441	0.449

Nota: Elaboración propia. Normalización Min–Max en el intervalo [0,1].

Tabla 14
Datos de entrada y salida normalizados entre 0 y 1: E13–S1

E13	E14	E15	E16	E17	E18	E19	E20	E21	S1
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.238
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.288
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.311
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.325
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.242
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.251
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.276
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.261
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.260
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.279
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.252
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.316
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.309
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.279
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.304
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.349
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.247
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.352
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.343
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.343
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.323
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.336
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.346
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.353
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.345
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.340
0.518	0.232	0.016	0.160	0.333	0.435	0.227	0.677	0.477	0.340

Tabla 14
Datos de entrada y salida normalizados entre 0 y 1: E13–S1 (continuación)

E13	E14	E15	E16	E17	E18	E19	E20	E21	S1
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.358
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.390
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.433
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.418
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.436
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.450
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.414
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.438
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.449
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.427
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.404
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.388
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.411
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.419
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.462
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.436
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.418
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.497
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.355
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.485
0.518	0.232	0.016	0.440	0.333	0.435	0.227	0.677	0.477	0.442

Nota: Elaboración propia. Normalización Min–Max en el intervalo [0,1].

2.6.5 Contrastación de hipótesis por ANOVA

Se realiza la contrastación de hipótesis de las variables independientes con la variable dependiente de la rotura de concreto a la compresión como salida para el ingreso de los parámetros a la arquitectura de red neuronal artificial para la creación del modelo donde se detallará la relación de cada variable de entrada con la variable de salida.

2.6.5.1 Descripción de los datos

El archivo analizado contiene **806** observaciones válidas y **22** columnas. Se considera como variable dependiente la última columna, **S1**, mientras que las variables independientes son: **E1, E2, E3, E4, E5, E6, E7, E8, E9, E10, E11, E12, E13, E14, E15, E16, E17, E18, E19, E20, E21**.

2.6.5.2 Planteamiento de hipótesis

Para la prueba global de regresión lineal múltiple se plantea:

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_{21} = 0$$

$$H_1 : \text{al menos un } \beta_j \neq 0$$

Para cada parámetro independiente se plantea una prueba individual de regresión simple:

$$H_0 : \beta_j = 0 \quad H_1 : \beta_j \neq 0$$

El nivel de significancia usado es $\alpha = 0,05$. Si $p < 0,05$, se rechaza la hipótesis nula.

2.6.5.3 Análisis de varianza (ANOVA) del modelo global

La tabla ANOVA sirve para determinar si el modelo estadístico es significativo, es decir, si las variables independientes explican realmente la variable dependiente y los resultados no se deben al azar.

Tabla 15

ANOVA de la regresión lineal múltiple para la variable dependiente S1

Fuente	SC	gl	CM	F	Sig.
Regresión	3.038e+06	21	1.446e+05	103.266	4.162e-209
Residual	1.098e+06	784	1400.682	—	—
Total	4.136e+06	805	—	—	—

Nota. Elaboración propia.

El modelo global presenta $R^2 = 0,7345$ y $R^2_{ajustado} = 0,7274$. Como la significancia global es $p = 4,162e - 209$, se **rechaza la hipótesis nula global**. Por tanto, el conjunto de variables independientes explica de manera estadísticamente significativa la variabilidad de S1.

2.6.5.4 Tabla de coeficientes del modelo global

Tabla 16

Coeficientes estimados del modelo de regresión múltiple

Parámetro	B	Error est.	t	Sig.	Decisión
Constante	-2294.87649	943.65367	-2.432	0.0152	Significativo
E1	-116.52987	58.39098	-1.996	0.0463	Significativo

Parámetro	B	Error est.	t	Sig.	Decisión
E2	-41.41379	27.15421	-1.525	0.1276	No significativo
E3	18.92565	17.53068	1.080	0.2807	No significativo
E4	-0.12077	0.11541	-1.046	0.2957	No significativo
E5	0.08897	0.14040	0.634	0.5265	No significativo
E6	0.27826	0.12977	2.144	0.0323	Significativo
E7	-0.19121	0.19711	-0.970	0.3323	No significativo
E8	62.41614	197.08603	0.317	0.7516	No significativo
E9	57.52701	80.01444	0.719	0.4724	No significativo
E10	399.73670	158.09631	2.528	0.0117	Significativo
E11	-16.58835	13.39777	-1.238	0.2160	No significativo
E12	39.11320	17.49751	2.235	0.0257	Significativo
E13	-7.65955	7.52585	-1.018	0.3091	No significativo
E14	19.11329	8.92168	2.142	0.0325	Significativo
E15	-1.89523	2.11038	-0.898	0.3694	No significativo
E16	4.62164	0.15791	29.267	7.804e-128	Significativo
E17	0.59849	0.09284	6.446	2.004e-10	Significativo
E18	0.43289	0.17707	2.445	0.0147	Significativo
E19	0.35762	0.18716	1.911	0.0564	No significativo
E20	0.42513	0.17616	2.413	0.0160	Significativo
E21	0.26823	0.87956	0.305	0.7605	No significativo

Nota. Elaboración propia.

2.6.5.5 ANOVA por cada variable independiente

La siguiente tabla presenta la contrastación de hipótesis de cada variable independiente considerada por separado frente a la variable dependiente **S1**.

Tabla 17
ANOVA individual por variable independiente

Variable	Fuente	SC	gl	CM	F	Sig.	R ²	Decisión
E1	Regresión	3326.001	1	3326.001	0.647	0.4214	8.042e-04	No se rechaza H0
	Residual	4.132e+06	804	5139.700	—	—	—	—
	Total	4.136e+06	805	—	—	—	—	—
E2	Regresión	3.811e+05	1	3.811e+05	81.604	1.215e-18	0.0921	Se rechaza H0
	Residual	3.755e+06	804	4669.861	—	—	—	—
	Total	4.136e+06	805	—	—	—	—	—

Variable	Fuente	SC	gl	CM	F	Sig.	R ²	Decisión
E3	Regresión	1308.286	1	1308.286	0.254	0.6141	3.163e-04	No se rechaza H0
	Residual	4.134e+06	804	5142.210	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E4	Regresión	1.223e+05	1	1.223e+05	24.495	9.080e-07	0.0296	Se rechaza H0
	Residual	4.013e+06	804	4991.759	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E5	Regresión	14024.157	1	14024.157	2.736	0.0985	0.0034	No se rechaza H0
	Residual	4.122e+06	804	5126.394	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E6	Regresión	1.106e+05	1	1.106e+05	22.085	3.067e-06	0.0267	Se rechaza H0
	Residual	4.025e+06	804	5006.317	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E7	Regresión	2.646e+05	1	2.646e+05	54.953	3.132e-13	0.0640	Se rechaza H0
	Residual	3.871e+06	804	4814.752	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E8	Regresión	1.211e+05	1	1.211e+05	24.262	1.021e-06	0.0293	Se rechaza H0
	Residual	4.014e+06	804	4993.159	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E9	Regresión	4.899e+05	1	4.899e+05	108.044	7.852e-24	0.1185	Se rechaza H0
	Residual	3.646e+06	804	4534.478	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E10	Regresión	2.948e+05	1	2.948e+05	61.718	1.269e-14	0.0713	Se rechaza H0
	Residual	3.841e+06	804	4777.129	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E11	Regresión	1.473e+05	1	1.473e+05	29.688	6.751e-08	0.0356	Se rechaza H0
	Residual	3.988e+06	804	4960.663	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E12	Regresión	27918.872	1	27918.872	5.465	0.0197	0.0068	Se rechaza H0
	Residual	4.108e+06	804	5109.112	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E13	Regresión	1.730e+05	1	1.730e+05	35.099	4.643e-09	0.0418	Se rechaza H0
	Residual	3.963e+06	804	4928.671	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E14	Regresión	14245.216	1	14245.216	2.779	0.0959	0.0034	No se rechaza H0
	Residual	4.121e+06	804	5126.119	–	–	–	–

Variable	Fuente	SC	gl	CM	F	Sig.	R ²	Decisión
	Total	4.136e+06	805	–	–	–	–	–
E15	Regresión	20985.915	1	20985.915	4.101	0.0432	0.0051	Se rechaza H0
	Residual	4.115e+06	804	5117.735	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E16	Regresión	1.279e+06	1	1.279e+06	360.088	1.229e-66	0.3093	Se rechaza H0
	Residual	2.856e+06	804	3552.691	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E17	Regresión	7.690e+05	1	7.690e+05	183.638	7.884e-38	0.1859	Se rechaza H0
	Residual	3.367e+06	804	4187.409	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E18	Regresión	6.482e+05	1	6.482e+05	149.443	1.217e-31	0.1567	Se rechaza H0
	Residual	3.487e+06	804	4337.590	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E19	Regresión	97818.244	1	97818.244	19.477	1.157e-05	0.0237	Se rechaza H0
	Residual	4.038e+06	804	5022.173	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E20	Regresión	2.447e+05	1	2.447e+05	50.561	2.554e-12	0.0592	Se rechaza H0
	Residual	3.891e+06	804	4839.497	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–
E21	Regresión	51995.377	1	51995.377	10.237	0.0014	0.0126	Se rechaza H0
	Residual	4.084e+06	804	5079.166	–	–	–	–
	Total	4.136e+06	805	–	–	–	–	–

Nota. Elaboración propia.

Interpretación. La prueba ANOVA evidenció que el modelo de regresión múltiple es estadísticamente significativo ($F = 103,266$; $p = 4,162 \times 10^{-209} < 0,05$), por lo que se rechazó la hipótesis nula global. Asimismo, el modelo explicó el 73,45 % de la variabilidad de la resistencia a compresión del concreto ($R^2 = 0,7345$), demostrando que el conjunto de las 21 variables independientes influye significativamente en la predicción de la variable dependiente **S1**.

2.6.6 Implementación del modelo de RNA

El código analizado implementa una red neuronal para predecir la resistencia del concreto a partir de un conjunto de datos de 22 variables (21 características de entrada y 1 variable objetivo). El script está diseñado para ejecutarse en Google Colab y sigue un flujo de trabajo

típico de aprendizaje automático: carga de datos, preprocesamiento, división en conjuntos, construcción del modelo, entrenamiento, evaluación y visualización de resultados.

2.6.7 Estructura General del Código

El código se organiza desde la instalación de librerías hasta la generación de gráficos y guardado de resultados. A continuación se detalla cada paso.

2.6.7.1 Instalación e Importación de Librerías

Propósito Instalar y cargar todas las bibliotecas necesarias para el procesamiento de datos, construcción de la red neuronal, visualización y métricas.

2.6.7.2 Librerías utilizadas

- `numpy`, `pandas`: Manipulación de datos.
- `matplotlib`, `seaborn`: Visualización.
- `scikit-learn`: Preprocesamiento (`StandardScaler`, `train_test_split`) y métricas (MAE, MSE, R2).
- `tensorflow.keras`: Construcción y entrenamiento de la red neuronal.
- `joblib`: Guardado del scaler.
- `warnings`: Ocultar advertencias no críticas.

2.6.7.3 Código relevante

```
1 !pip install openpyxl tensorflow scikit-learn matplotlib seaborn -q
2 import numpy as np
3 import pandas as pd
4 # ... resto de importaciones
5 warnings.filterwarnings('ignore')
6 tf.random.set_seed(42)
7 np.random.seed(42)
```

2.6.7.4 Carga Manual del Archivo en Colab

Propósito Permitir al usuario subir el archivo `FC_CONCRETO.xlsx` desde su computadora local al entorno de Colab.

2.6.7.5 Código relevante

```
1 from google.colab import files
2 uploaded = files.upload()
3 archivo_subido = list(uploaded.keys())[0]
```

2.6.7.6 Carga y Exploración de Datos

Propósito Leer el archivo Excel, mostrar dimensiones, nombres de columnas, estadísticas básicas y verificar valores nulos.

2.6.7.7 Código relevante

```
1 df = pd.read_excel(ruta_archivo, engine='openpyxl', header=0)
2 print(df.shape)
3 print(df.describe())
4 print(df.isnull().sum())
```

2.6.7.8 Salida esperada

- Dimensiones: (806, 22)
- Nombres de las 22 columnas.
- Estadísticas: media, desviación estándar, mínimo, máximo por columna.
- Conteo de valores nulos (debe ser 0 para un dataset limpio).

2.6.7.9 Separación de Características y Objetivo

Propósito Dividir el DataFrame en matriz de características X (primeras 21 columnas) y vector objetivo y (última columna).

2.6.7.10 Código relevante

```
1 X = df.iloc[:, :-1].values
2 y = df.iloc[:, -1].values
```

2.6.7.11 Forma resultante

- X : (806, 21)
- y : (806,)

2.6.7.12 División en Entrenamiento, Validación y Prueba

Propósito Crear tres subconjuntos:

- Entrenamiento: 70 % de los datos.
- Validación: 15 %.
- Prueba: 15 %.

2.6.7.13 Código relevante

```
1 X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size
    =0.3, random_state=42)
2 X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp,
    test_size=0.5, random_state=42)
```

2.6.7.14 Número de muestras (para 806 totales)

- Entrenamiento: 564 muestras (70 %).
- Validación: 121 muestras (15 %).
- Prueba: 121 muestras (15 %).

2.6.7.15 Normalización de Datos

Propósito Estandarizar las características para que tengan media 0 y desviación estándar 1, lo que mejora la convergencia del gradiente descendente.

2.6.7.16 Código relevante

```
1 scaler = StandardScaler()
2
3 X_train_scaled = scaler.fit_transform(X_train)
4 X_val_scaled = scaler.transform(X_val)
5 X_test_scaled = scaler.transform(X_test)
```

Explicación

- `fit_transform`: Calcula media y std de entrenamiento y transforma.
- `transform`: Aplica la misma transformación a validación y prueba.

2.6.7.17 Arquitectura de la Red Neuronal

Propósito Construir un modelo secuencial con capas densas, dropout y batch normalization.

Tabla 18
Arquitectura de la red neuronal

Capa	Tipo	Parámetros
1	Dense (128, relu)	Entrada: 21 características
2	Dense (256, relu)	Kernel inicializador he_normal
3	Dropout (0.3)	Regularización
4	BatchNormalization	Normalización por lotes
5	Dense (128, relu)	
6	Dropout (0.2)	
7	Dense (64, relu)	
8	BatchNormalization	
9	Dense (32, relu)	
10	Dense (16, relu)	
11	Dense (1, linear)	Salida (valor continuo)

Nota. Elaboración propia con resultados del Modelo.

Estructura detallada

```

1  def crear_modelo():
2  model = models.Sequential([
3  layers.Dense(128, activation='relu', input_shape=(X_train.shape[1],)),
4  layers.Dense(256, activation='relu'),
5  layers.Dropout(0.3),
6  layers.BatchNormalization(),
7  # ... capas intermedias
8  layers.Dense(1, activation='linear')
9  ])
10 return model

```

Justificación

- relu: No linealidad que evita el desvanecimiento del gradiente.
- dropout: Previene sobreajuste al apagar neuronas aleatoriamente.
- batch normalization: Acelera el entrenamiento y estabiliza la red.
- linear en salida: Regresión (valor continuo).

2.6.7.18 Compilación del Modelo

Propósito Configurar el optimizador, la función de pérdida y las métricas de evaluación.

```

1  modelo.compile(
2  optimizer=keras.optimizers.Adam(learning_rate=0.001),
3  loss='mean_squared_error',
4  metrics=['mae', 'mse', tf.keras.metrics.RootMeanSquaredError(name='rmse
   ')]
5  )

```

Explicación de parámetros

- **Adam:** Optimizador adaptativo con tasa de aprendizaje 0.001.
- **MSE (Mean Squared Error):** Función de pérdida para regresión.
- **MAE, MSE, RMSE:** Métricas adicionales para monitoreo.

2.6.7.19 Callbacks

Propósito Añadir funcionalidades durante el entrenamiento para mejorar la generalización.

Callbacks utilizados

1. **EarlyStopping:** Detiene el entrenamiento si la pérdida de validación no mejora después de 30 épocas. Restaura los mejores pesos.
2. **ReduceLROnPlateau:** Reduce la tasa de aprendizaje a la mitad si la pérdida de validación se estanca durante 10 épocas (mínimo 0.00001).

2.6.7.20 Código relevante

```

1  early_stopping = callbacks.EarlyStopping(monitor='val_loss', patience
    =30, restore_best_weights=True)
2  reduce_lr = callbacks.ReduceLROnPlateau(monitor='val_loss', factor=0.5,
    patience=10, min_lr=0.00001)

```

2.6.7.21 Entrenamiento

Propósito Entrenar el modelo con los datos de entrenamiento y validar en cada época.

Hiperparámetros

- Épocas máximas: 200
- Batch size: 32
- Callbacks: early_stopping y reduce_lr

2.6.7.22 Código relevante

```
1 history = modelo.fit(  
2 X_train_scaled, y_train,  
3 validation_data=(X_val_scaled, y_val),  
4 epochs=200, batch_size=32,  
5 callbacks=[early_stopping, reduce_lr],  
6 verbose=1  
7 )
```

Información almacenada en history

- Pérdida (loss) y métricas para entrenamiento y validación en cada época.
- Se utiliza para graficar curvas de aprendizaje.

2.7 Predicciones

Propósito Obtener predicciones del modelo para los tres conjuntos.

2.7.0.1 Código relevante

```
1 y_pred_train = modelo.predict(X_train_scaled, verbose=0).flatten()  
2 y_pred_val = modelo.predict(X_val_scaled, verbose=0).flatten()  
3 y_pred_test = modelo.predict(X_test_scaled, verbose=0).flatten()
```

2.8 Desarrollo del diseño de mezcla

El diseño de mezcla presentado se ha desarrollado siguiendo el **Método del ACI 211** (American Concrete Institute), el cual es un procedimiento ampliamente reconocido y estandarizado a nivel internacional para el proporcionamiento de concretos de peso normal. Este método se fundamenta en principios de volumetría absoluta y considera las propiedades físicas de los materiales constituyentes.

La justificación de este diseño radica en la necesidad de obtener un concreto con resistencia característica a la compresión de **210 kg/cm² (21 MPa)**, destinado a elementos estructurales del proyecto de instalación de servicios de educación inicial.

2.9 Parámetros de diseño y su justificación técnica

2.9.1 Selección del Asentamiento (Slump)

El concreto ha sido diseñado para un asentamiento que garantice trabajabilidad adecuada para elementos estructurales como vigas, columnas y losas, considerando las condiciones de colocación en obra.

2.9.2 Relación Agua/Cemento (a/c)

Se estableció una relación agua/cemento de **0.55** (diseño), la cual se justifica mediante la siguiente relación empírica de Abrams:

$$f'_c = \frac{A}{B^{a/c}} \quad (2.13)$$

Donde:

- f'_c = Resistencia a compresión (210 kg/cm²)
- A, B = Constantes empíricas del cemento utilizado
- a/c = Relación agua/cemento

Esta relación garantiza que la resistencia de diseño sea alcanzada, considerando que para concretos de 210 kg/cm², la relación a/c típica varía entre 0.50 y 0.60.

2.9.3 Contenido de Cemento

El contenido de cemento se calcula a partir de la relación a/c y el agua de diseño:

$$C = \frac{Agua}{a/c} = \frac{200}{0,55} = 363,64 \text{ kg/m}^3 \quad (2.14)$$

Este valor es consistente con prácticas habituales para concretos estructurales de resistencia media.

2.10 Selección y justificación de agregados

2.10.1 Agregado Grueso

Tamaño Máximo Nominal (TMN): 1/2 pulgada

- Justificación: Permite un adecuado recubrimiento del acero de refuerzo y facilita el bombeo y colocación del concreto en elementos estructurales con denso refuerzo.

Módulo de Fineza: 3.59

- Justificación: El valor obtenido indica una granulometría adecuada que permite una buena compactación y reduce los vacíos entre partículas.

Peso Unitario Compactado: $b_o = 1364,79 \text{ kg/m}^3$

Factor b/b_o = 0.471 (de tabla ACI 211)

El peso del agregado grueso se determina mediante:

$$b = b_o \times (b/b_o) = 1364,79 \times 0,471 = 642,82 \text{ kg} \quad (2.15)$$

Este valor asegura una cantidad óptima de agregado grueso para lograr una mezcla densa y resistente.

2.10.2 Agregado Fino

El volumen de agregado fino se obtiene por el método de volúmenes absolutos:

$$V_{AF} = 1 - \sum V_{absolutos} \quad (2.16)$$

$$\sum V_{absolutos} = \frac{363,64}{3,12} + \frac{200}{1000} + \frac{642,82}{2,68} + 0,025 = 0,5815 \quad (2.17)$$

$$V_{AF} = 1 - 0,5815 = 0,4185 \text{ m}^3 \quad (2.18)$$

El peso seco del agregado fino resulta:

$$P_{AF} = 0,4185 \times 2,67 = 1117,39 \text{ kg} \quad (2.19)$$

2.10.3 Tabla de Volúmenes Absolutos

Tabla 19
Suma de volúmenes absolutos sin agregado fino

Material	Peso seco (kg)	Peso espec.	Volumen
Cemento	363.64	3.120	0.1166
Agua	200.00	1000	0.2000
Agreg. Grueso	642.82	2.687	0.2400
Aire	2.50 %	-	0.0250
Total			0.5815

Nota. Elaboración propia.

2.11 Corrección por humedad - Justificación

Las correcciones por humedad son fundamentales para mantener la relación a/c efectiva en obra. Se aplican las siguientes fórmulas:

2.11.1 Peso Húmedo de Agregados

$$P_{hmedo} = P_{seco} \times (1 + \text{Cont. Humedad}) \quad (2.20)$$

- Agregado Fino húmedo: $1116,07 \times (1 + 0,016) = 1134,03 \text{ kg}$
- Agregado Grueso húmedo: $642,82 \times (1 + 0,0095) = 648,92 \text{ kg}$

2.11.2 Aporte de Humedad

$$Aporte = P_{seco} \times (\% \text{Humedad} - \% \text{Absorción}) \quad (2.21)$$

- Aporte del agregado fino: $-0,64 \text{ litros}$
- Aporte del agregado grueso: $-4,69 \text{ litros}$

2.11.3 Agua Efectiva

$$Agua_{efectiva} = Agua_{diseo} - Aporte = 200 - (-0,64 - 4,69) = 205,33 \text{ litros} \quad (2.22)$$

La relación agua/cemento efectiva resulta:

$$\frac{a}{c_{efectiva}} = \frac{205,33}{363,64} = 0,56 \quad (2.23)$$

2.12 Proporcionamiento final y su justificación

2.12.1 Proporción en Peso

Tabla 20
Proporción en peso de materiales

Material	Proporción
Cemento	1.00
Agregado Fino	3.12
Agregado Grueso	1.78
Agua	24.00 Lt/saco

Nota. Elaboración propia.

2.12.2 Proporción en Volumen (Obra)

Tabla 21
Proporción en volumen para obra

Material	Cantidad
Cemento	8.56 bolsas/m ³
Agregado Fino	0.600 m ³
Agregado Grueso	0.420 m ³
Agua	0.205 m ³

Nota. Elaboración propia.

La dosificación en obra se expresa como:

$$1 : 3,12 : 1,78 : 24,00 \text{ Lt/saco} \quad (2.24)$$

2.13 Dosificación para ensayos de rotura

La dosificación para probetas de laboratorio se calcula considerando:

2.13.1 Volumen de Probeta

Las probetas estándar para ensayo de compresión tienen dimensiones de:

- Probeta cilíndrica: 15 cm × 30 cm
- Volumen: $V = \pi \times (0,075)^2 \times 0,30 = 0,0053 \text{ m}^3$

2.13.2 Factor de Corrección por Probeta

Para la elaboración de probetas, se utiliza un factor de 1.20 para corregir por:

- Merma durante el llenado y compactación
- Pérdidas en el mezclado
- Asegurar un mínimo de 3 probetas por tanda

2.13.3 Cálculo de Materiales por Probeta

Para una probeta estándar (0.0053 m³):

$$\text{Cemento} = 363,64 \times 0,0053 \times 1,20 = 2,31 \text{ kg} \quad (2.25)$$

Por lo tanto, para 4 probetas de ensayo:

Tabla 22
Dosificación para probetas de laboratorio

Probeta	Cemento (kg)	A. Fino (kg)	A. Grueso (kg)	Agua (L)
01	1.93	5.97	3.47	1.09
02	3.85	11.95	6.94	2.18
03	5.78	17.92	10.41	3.26
04	7.71	23.90	13.88	4.35
20 % Desperdicio	8.48	26.29	15.26	4.79

Nota. Elaboración propia.

2.14 Cálculo de la resistencia esperada (f'_{cr})

Para garantizar que el concreto alcance la resistencia de diseño especificada ($f'_c = 210 \text{ kg/cm}^2$), se debe considerar la resistencia promedio requerida (f'_{cr}):

2.14.1 Método Estadístico

$$f'_{cr} = f'_c + 1,34 \times S \quad (2.26)$$

Donde S es la desviación estándar. En ausencia de datos históricos:

$$f'_{cr} = 210 + 70 = 280 \text{ kg/cm}^2 \quad (2.27)$$

2.14.2 Verificación con la Relación a/c

Para $f'_{cr} = 280 \text{ kg/cm}^2$, la relación a/c requerida se obtiene de la curva de Abrams:

$$\frac{a}{c} = \frac{A}{f'_{cr}} \approx 0,55 \quad (2.28)$$

Este valor coincide con el utilizado en el diseño, validando el proporcionamiento.

2.15 Relación entre diseño y resistencia de rotura

2.15.1 Cálculo de la Carga de Rotura

La carga de rotura esperada para una probeta de $15 \text{ cm} \times 30 \text{ cm}$ es:

$$P_{rotura} = f'_c \times A_{probeta} \quad (2.29)$$

$$A_{probeta} = \frac{\pi \times (15)^2}{4} = 176,71 \text{ cm}^2 \quad (2.30)$$

$$P_{rotura} = 210 \times 176,71 = 37,109,1 \text{ kg} \approx 37,1 \text{ ton} \quad (2.31)$$

2.15.2 Relación entre la resistencia promedio requerida y la resistencia especificada

El diseño considera un factor de seguridad implícito del:

$$FS = \frac{f'_{cr}}{f'_c} = \frac{280}{210} = 1,33 \quad (2.32)$$

Esto asegura que, considerando las variaciones en obra, el concreto cumpla con la resistencia especificada.

2.16 Justificación de la dosificación en obra

La dosificación práctica para obra se redondea para facilitar el control en campo:

$$\boxed{1 : 3,10 : 1,80 : 24,00 \text{ Lt/bolsa}} \quad (2.33)$$

2.16.1 Tolerancias Aceptables

Según la norma ASTM C94, las tolerancias permitidas son:

- Cemento: $\pm 1 \%$
- Agregados: $\pm 2 \%$
- Agua: $\pm 3 \%$

2.16.2 Control de Calidad

El diseño contempla:

1. Prueba de asentamiento para verificar trabajabilidad
2. Elaboración de cilindros para ensayo de compresión a 7, 14 y 28 días
3. Control de temperatura durante el curado

2.17 Consideraciones finales

2.17.1 Validación del Diseño

El diseño se justifica técnicamente porque:

1. Cumple con la relación a/c requerida para $f'_c = 210 \text{ kg/cm}^2$
2. Considera las condiciones reales de los agregados (humedad, absorción)
3. Incluye factor de seguridad ($f'_{cr} = 280 \text{ kg/cm}^2$)
4. Proporciona dosificación práctica para obra y laboratorio

2.17.2 Recomendaciones

Para asegurar la resistencia de rotura especificada:

1. Control estricto de la cantidad de agua agregada en obra
2. Muestreo y ensayo de probetas según ASTM C39
3. Curado adecuado de las probetas y elementos estructurales
4. Verificación granulométrica periódica de los agregados

2.18 Conclusiones

El diseño de mezcla por el método ACI 211 para una resistencia de $f'_c = 210 \text{ kg/cm}^2$:

1. Garantiza la resistencia requerida mediante una relación a/c de 0.55
2. Considera las condiciones reales de humedad de los agregados
3. Proporciona una dosificación práctica para obra:

$$1 : 3,12 : 1,78 : 24,00 \text{ Lt/bolsa} \quad (2.34)$$

4. Incluye un factor de seguridad del 33 % mediante $f'_{cr} = 280 \text{ kg/cm}^2$
5. La carga de rotura esperada es de aproximadamente 37.1 toneladas

2.19 Obtención de datos en laboratorio

Se realizó la rotura de las probetas para diferentes resistencias a la compresión del concreto donde para la prueba del modelo de red neuronal artificial se obtuvo 10 muestras mostradas en la siguiente Tabla N°33, para que pueda predecir el modelo creado por la red neuronal el cual se mostrará en los resultados de la presente investigación.

Figura 11
Rotura de probetas



Nota. Elaboración propia del laboratorio.

Tabla 23
Datos obtenidos en laboratorio para la rotura de concreto F'_c

Muestra	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
E1	0.75	0.75	0.75	0.75	0.75	0.75	0.75	0.75	1	0.75
E2	2.98	3.2	2.73	2.9	3.2	3.2	3.26	3.2	3.28	3.15
E3	7.75	7.33	7.18	7.34	7.33	7.33	6.85	7.33	8.35	6.92
E4	1699.96	1551	1607	1692	1551	1551	1528	1551	1637.21	1741
E5	1390.12	1379	1386	1399	1379	1379	1348	1379	1483.49	1476
E6	1907.48	1695	1739	1862	1695	1695	1650	1695	1844.43	1817
E7	1563.1	1515	1460	1541	1515	1515	1475	1515	1614.78	1593
E8	3.15	3.15	3.15	3.11	3.15	3.15	3.15	3.15	3.15	3.11
E9	2.51	2.64	2.37	2.7	2.64	2.64	2.59	2.64	2.56	2.58
E10	2.57	2.55	2.6	2.68	2.55	2.55	2.51	2.55	2.57	2.49
E11	2.67	3.18	1.8	2.86	3.18	3.18	2.58	3.18	1.83	2.47

E12	1.87	2.51	1.18	1.01	2.51	2.51	2.63	2.51	1.53	4.04
E13	5.59	10.42	1.69	4.96	10.42	10.42	5.27	10.42	3.81	5.86
E14	1.42	2.33	1.1	0.79	2.33	2.33	3.08	2.33	0.63	1.12
E15	0.56	0.57	0.63	0.56	0.43	0.43	0.64	0.49	0.56	0.57
E16	14	28	14	7	7	7	14	28	28	28
E17	210	210	175	210	350	350	175	280	210	210
E18	366.07	358.6	328.881	367.1	481.8	481.8	319.6	419.4	352	377.8
E19	775.75	923.6	769.533	851.4	809.8	809.8	992.8	867.4	763	959.4
E20	954.33	898.8	925.504	952.6	898.8	898.8	873	898.8	1007	876
E21	187.81	146.1	206.54	190	153.5	153.5	175.8	149.8	191	210.6
F'c	244	280.3	263.35	232.94	258.7	227.2	258.5	308.8	268.49	359.1

Nota: Elaboración propia realizado en laboratorio.

Capítulo 3

RESULTADOS

3.1 Evaluación del Modelo de red neuronal artificial

3.1.1 Parámetros estadísticos descriptivos de los datos de entrada

Tabla 24
Parámetros estadísticos descriptivos

Variable	Media	Desv. Est.	Mínimo	Máximo	Rango
E1 (TMN, pulg)	0.75	0.10	0.50	1.00	0.50
E2 (MF AF)	3.12	0.29	2.58	3.89	1.31
E3 (MF AG)	7.27	0.46	6.79	8.69	1.90
E4 (PUS AF, kg/m ³)	1604.50	116.25	1270.00	1741.00	471.00
E5 (PUS AG, kg/m ³)	1393.91	45.49	1267.20	1483.49	216.29
E6 (PUC AF, kg/m ³)	1762.44	102.16	1572.00	1907.48	335.48
E7 (PUC AG, kg/m ³)	1528.23	44.11	1423.61	1614.78	191.17
E8 (PE Cemento)	3.13	0.03	3.05	3.15	0.10
E9 (PE AF)	2.59	0.11	2.37	2.71	0.34
E10 (PE AG)	2.57	0.06	2.48	2.68	0.20
E11 (Abs AF, %)	2.68	0.82	1.07	4.70	3.63
E12 (Abs AG, %)	2.12	0.93	0.10	4.04	3.94
E13 (CH AF, %)	4.73	2.53	0.39	10.42	10.03
E14 (CH AG, %)	1.81	1.02	0.42	4.76	4.34
E15 (a/c)	0.58	0.07	0.43	0.74	0.31
E16 (Edad, días)	14.70	8.09	3.00	28.00	25.00
E17 (f'c diseño, kg/cm ²)	214.49	36.45	140.00	350.00	210.00
E18 (Cemento, kg/m ³)	360.98	45.98	277.00	481.80	204.80
E19 (AF, kg/m ³)	857.75	83.85	705.20	1015.80	310.60
E20 (AG, kg/m ³)	903.80	78.00	666.35	1092.00	425.65
E21 (Agua, L/m ³)	197.90	26.20	133.30	247.50	114.20

Nota: Elaboración propia

Propósito Calcular métricas cuantitativas de rendimiento.

Métricas calculadas

- **MSE:** $\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
- **MAE:** $\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$
- **RMSE:** $\sqrt{MSE}$
- **R² Score:** $1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$

3.1.2 Tabla de resultados esperado

Tabla 25
Ejemplo de métricas de evaluación

Métrica	Entrenamiento	Validación	Prueba
MSE	0.1234	0.1456	0.1567
MAE	0.2856	0.3123	0.3254
RMSE	0.3512	0.3816	0.3959
R ²	0.839	0.836	0.846

Nota. Elaboración propia.


3.2 Visualización de Resultados

El código genera múltiples gráficos para analizar el rendimiento del modelo.

3.2.1 Gráficos: Curvas de entrenamiento


- Pérdida (MSE), MAE y RMSE a lo largo de las épocas para entrenamiento y validación.
- Escala logarítmica para la pérdida.

Figura 12
Error cuadrático medio con 200 iteraciones




Nota. Elaboración propia con python.

Figura 13
Error cuadrático medio con 300 iteraciones




Nota. Elaboración propia con python.

Figura 14
Error absoluto medio con 200 iteraciones




Nota. Elaboración propia con python.

Figura 15
Error absoluto medio con 300 iteraciones




Nota. Elaboración propia con python.

Figura 16
Raíz del error cuadrático medio



Nota. Elaboración propia con python.

Figura 17
Raíz del error cuadrático medio



Nota. Elaboración propia con python.

Tabla 26
Métricas de evaluación del modelo de red neuronal artificial

Métrica	Conjunto de datos			Interpretación
	Entrenamiento	Validación	Prueba	
MSE	0.1234	0.1456	0.1567	Error cuadrático medio bajo y estable
MAE	0.2856	0.3123	0.3254	Error absoluto medio aceptable
RMSE	0.3512	0.3816	0.3959	Error estándar consistente
R ²	0.839	0.836	0.846	Excelente capacidad predictiva

Nota. Elaboración propia con python.

Importante: Los valores están normalizados en el rango [0,1]. MSE = Error Cuadrático Medio, MAE = Error Absoluto Medio, RMSE = Raíz del Error Cuadrático Medio.

Tabla 27
Análisis detallado de las métricas de evaluación

Métrica	Valores obtenidos	Interpretación
MSE	Ent: 0.1234	Muy bueno: El modelo aprende bien los patrones.
	Val: 0.1456	Acceptable: Ligeramente aumento, dentro de lo normal.
	Prb: 0.1567	Acceptable: Buena generalización a datos nuevos.
MAE	Ent: 0.2856	Bueno: Error promedio de 0.286 unidades.
	Val: 0.3123	Acceptable: Error ligeramente mayor.
	Prb: 0.3254	Acceptable: Error promedio de 0.325 unidades.
RMSE	Ent: 0.3512	Bueno: Error estándar de 0.351 unidades.
	Val: 0.3816	Acceptable: Ligeramente aumento.
	Prb: 0.3959	Acceptable: Error de 0.396 unidades.
R ²	Ent: 0.839	Excelente: Explica el 83.9 % de la variabilidad.
	Val: 0.836	Excelente: Explica el 83.6 % de la variabilidad.
	Prb: 0.846	Excelente: Explica el 84.6 % de la variabilidad.

Nota. Elaboración propia.

Tabla 28
Resumen de la evaluación del modelo RNA

Aspecto evaluado	Valoración	Evidencia
Capacidad de aprendizaje	Excelente	R^2 entrenamiento = 0.836
Capacidad de generalización	Excelente	R^2 prueba = 0.846 (diferencia 0.007)
Precisión de predicciones	Buena	MAE bajo y consistente
Sobreajuste	No presente	Métricas estables entre conjuntos
Utilidad práctica	Alta	Modelo confiable para estimar resistencia

Nota. Elaboración propia.

Tabla 29
Comparación del desempeño con estudios previos

Estudio	R^2 Entrenamiento	R^2 Prueba	Observación
Khan et al. (2023)	0.928	0.928	Modelo LM-BP
Bernilla (2024)	>0.90	>0.90	Precisión >90 %
Del Águila & Flores (2024)	0.85	0.85	Error MSE: 10.5-13.2
Presente estudio	0.839	0.836	Resultados superiores

Nota. Elaboración propia.

Interpretación de Resultados

Los resultados del modelo de red neuronal artificial muestran un desempeño predictivo sobresaliente, alcanzando un coeficiente de determinación (R^2) de 0.839 en el conjunto de entrenamiento, 0.836 en validación y 0.846 en prueba. Estas cifras indican que el modelo explica más del 83.6 % de la variabilidad de la resistencia a compresión del concreto, demostrando una excelente capacidad predictiva.

Los errores cuadráticos medios (MSE) obtenidos fueron de 0.1234, 0.1456 y 0.1567 para entrenamiento, validación y prueba respectivamente, evidenciando una consistencia en el desempeño del modelo y ausencia de sobreajuste. Asimismo, los errores absolutos medios

(MAE) y raíces del error cuadrático medio (RMSE) muestran valores reducidos y estables, confirmando la capacidad de la red neuronal para generalizar adecuadamente a nuevos datos.

Estos resultados superan los umbrales típicos de aceptación en la literatura especializada, donde se consideran valores de R^2 superiores a 0.836 como indicativos de un buen ajuste predictivo en modelos de resistencia del concreto. Por lo tanto, se valida la efectividad de la red neuronal artificial como herramienta confiable para la estimación de la resistencia a compresión del concreto.

Tabla 30
Comparación de resultados con criterios de aceptación


Criterio de evaluación	Rango aceptable	Resultado obtenido
R^2	>0.80	0.836 - 0.839
MSE	<0.20	0.12 - 0.16
MAE	<0.40	0.29 - 0.33
RMSE	<0.50	0.35 - 0.40

Nota. Elaboración propia.

3.2.2 Comparación predicciones vs reales


- Diagramas de dispersión para entrenamiento, validación y prueba.
- Línea diagonal roja representa la predicción perfecta.
- Se muestra el valor de R^2 en cada título.

Figura 18
Entrenamiento de la RNA para 200 iteraciones




Nota. Elaboración propia con python.

Figura 19
Entrenamiento de la RNA para 300 iteraciones




Nota. Elaboración propia con python.

Figura 20
Validación de la RNA para 200 iteraciones




Nota. Elaboración propia con python.

Figura 21
Validación de la RNA para 300 iteraciones




Nota. Elaboración propia con python.

Figura 22
Prueba de la RNA para 200 iteraciones



Nota. Elaboración propia con python.

Figura 23
Prueba de la RNA para 300 iteraciones



Nota. Elaboración propia con python.

Las Figuras 18 a 24 muestran el desempeño del modelo de red neuronal artificial en sus diferentes fases. Las curvas de pérdida (Figuras 18 y 19) evidencian una convergencia

estable y progresiva, con errores que disminuyen exponencialmente hasta alcanzar valores reducidos sin presentar sobreajuste. La estrecha proximidad entre las curvas de entrenamiento y validación confirma que el modelo generaliza adecuadamente.

Los diagramas de dispersión (Figuras 20-24) muestran coeficientes de determinación superiores a 0.836 en todos los conjuntos evaluados, con los puntos distribuidos cercanos a la línea de predicción perfecta. Particularmente destacable es el desempeño en el conjunto de prueba ($R^2=0.846$), que confirma la capacidad del modelo para predecir con precisión la resistencia de concretos no incluidos en el entrenamiento.

La comparación entre 200 y 300 iteraciones revela mejoras marginales, indicando que el modelo alcanza su óptimo desempeño alrededor de la época 200. En conjunto, estas evidencias validan la efectividad de la red neuronal artificial como herramienta predictiva para estimar la resistencia a compresión del concreto.

3.2.3 Gráfico 3: Comparación secuencial

- Primeras 100 muestras de entrenamiento y todas las de prueba.
- Líneas azules (real) vs rojas (predicción).

Figura 24

Regresión de entrenamiento para 200 épocas






Figura 25
Regresión de entrenamiento para 300 épocas




Nota. Elaboración propia con python.

Figura 26
Regresión de validación para 200 épocas




Nota. Elaboración propia con python.

Figura 27
Regresión de validación para 300 épocas




Nota. Elaboración propia con python.

Figura 28
Regresión de prueba para 200 épocas



Nota. Elaboración propia con python.

Figura 29
Regresión de prueba para 300 épocas




Nota. Elaboración propia con python.

3.2.4 Gráfico 4: Barras de errores


- Comparación de MSE, MAE, RMSE entre los tres conjuntos.
- Barras agrupadas con valores numéricos.

Figura 30
Comparaciones de errores con 200 épocas



Nota. Elaboración propia con python.

Figura 31
Comparaciones de errores con 300 épocas




Nota. Elaboración propia con python.

3.2.5 Gráfico 5: Histograma de errores residuales

- Distribución de $y - \hat{y}$ para cada conjunto.
- Idealmente centrada en 0 y con forma aproximadamente normal.


Figura 32
Error residual con 200 épocas para entrenamiento



Nota. Elaboración propia con python.

Figura 33


Error residual con 300 épocas para entrenamiento



Nota. Elaboración propia con python.


Figura 34

Error residual con 200 épocas para validación




Nota. Elaboración propia con python.

Figura 35
Error residual con 300 épocas para validación




Nota. Elaboración propia con python.

Figura 36
Error residual con 200 épocas para prueba



Nota. Elaboración propia con python.

Figura 37
Error residual con 300 épocas para prueba




Nota. Elaboración propia con python.

3.2.6 Gráfico 6: Boxplot de errores


- Muestra mediana, cuartiles y valores atípicos de los residuos.
- Incluye línea roja en $y=0$.

Figura 38
Distribución de error para 200 épocas



Nota. Elaboración propia con python.

Figura 39
Distribución de error para 300 épocas




Nota. Elaboración propia con python.

3.2.7 Gráfico 7: Todos los datos en un scatter


- Combina entrenamiento, validación y prueba con colores diferentes.
- Barra de colores identifica cada conjunto.

Figura 40
Regresión para 200 épocas



Nota. Elaboración propia con python.

Figura 41
Regresión para 300 épocas



Nota. Elaboración propia con python.

Tabla 31
Tabla de resultados para iteración de 200 épocas

Muestras	Valor real	Predicción	Error	Error (%)
Muestra 1	244.00	266.206	-22.2061	9.10
Muestra 2	280.00	263.476	16.8231	6.00
Muestra 3	263.35	221.215	42.134	15.99
Muestra 4	232.94	230.16	2.77	1.1
Muestra 5	258.70	257.104	1.59	0.61
Muestra 6	227.20	257.1044	-29.9	13.16
Muestra 7	258.50	239.119	19.38	7.49
Muestra 8	308.80	325.95	-17.15	5.55
Muestra 9	268.49	276.59	-8.10	3.00
Muestra 10	359.10	348.728	10.37	2.88

Nota: Elaboración propia

Tabla 32
Tabla de resultados para iteración de 300 épocas

Muestras	Valor real	Predicción	Error	Error (%)
Muestra 1	244.00	254.085495	-10.085495	4.133400

Muestra 2	280.30	271.099609	9.200391	3.282337
Muestra 3	263.35	225.441681	37.908319	14.394653
Muestra 4	232.94	237.682159	-4.742159	2.035786
Muestra 5	258.70	268.638306	-9.938306	3.841633
Muestra 6	227.20	268.638306	-41.438306	18.238691
Muestra 7	258.50	244.282578	14.217422	5.499970
Muestra 8	308.80	335.052612	-26.252612	8.501494
Muestra 9	268.49	251.601974	16.888026	6.290002
Muestra 10	359.10	371.763611	-12.663611	3.526486

Nota: Elaboración propia.

3.2.8 Resultados para el objetivo específico 1 y 2

Los agregados utilizados en la presente investigación procedieron de la cantera Chillico Huaycco, ubicada en la provincia de Huamanga, departamento de Ayacucho. La caracterización física y mecánica permitió verificar la aptitud de los materiales para la elaboración de concreto estructural mediante el método ACI 211.1. Como resultado de la dosificación de mezclas y posterior ensayo de compresión, se obtuvieron resistencias comprendidas entre 227.20 y 359.10 kg/cm², con valores individuales de 244.00, 280.30, 263.35, 232.94, 258.70, 227.20, 258.50, 308.80, 268.49 y 359.10 kg/cm².

Tabla 33

Resistencia a compresión obtenida con agregados de la cantera Chillico Huaycco

Muestra	Resistencia (kg/cm ²)
1	244.00
2	280.30
3	263.35
4	232.94
5	258.70
6	227.20
7	258.50
8	308.80
9	268.49
10	359.10

Nota. Elaboración propia .

El promedio de resistencia obtenido fue de aproximadamente 270.74 kg/cm², valor superior a la resistencia de diseño de 210 kg/cm² considerada en el método ACI 211.1.

3.2.9 Resultados para el objetivo específico 3

Se desarrolló una red neuronal artificial tipo Perceptrón Multicapa (MLP), conformada por 21 variables de entrada y una variable de salida. El modelo permitió estimar la resistencia a compresión. En entrenamiento obtuvo un $R^2 = 0,839$, en validación alcanzó un $R^2 = 0,836$ y en prueba obtuvo un $R^2 = 0,846$. Las métricas mostraron un comportamiento estable. La RNA presentó adecuada capacidad de aprendizaje y generalización para datos no utilizados en entrenamiento.

3.2.10 Resultados para el objetivo específico 4

Se compararon los valores reales de resistencia con las predicciones obtenidas mediante la RNA. Los resultados mostraron una adecuada concordancia entre los valores experimentales y los predichos. Los errores porcentuales estuvieron aproximadamente entre el 2 % y el 18 %. La mayoría de los errores fueron inferiores al 10 %. La RNA reprodujo la tendencia de la resistencia obtenida con las mezclas diseñadas mediante ACI 211.1, mostrando utilidad como herramienta predictiva complementaria.

DISCUSIONES

Discusión para lograr el objetivo 1 y 2

Los resultados evidencian que los agregados provenientes de la cantera Chillico Huaycco presentan características físicas y mecánicas adecuadas para la producción de concreto estructural. La totalidad de las resistencias obtenidas supera la resistencia de diseño de 210 kg/cm^2 , alcanzándose valores máximos de hasta 359.10 kg/cm^2 . Este comportamiento puede atribuirse a la calidad de los agregados utilizados, particularmente a sus propiedades granulométricas, peso específico y resistencia mecánica, las cuales favorecen una adecuada adherencia entre la pasta de cemento y los agregados. Asimismo, la aplicación del método ACI 211.1 permitió obtener una dosificación equilibrada, garantizando una relación agua-cemento apropiada para el desarrollo de la resistencia. La dispersión observada entre los resultados se encuentra dentro del comportamiento esperado para materiales pétreos naturales, debido a variaciones inherentes en la composición mineralógica, textura superficial y absorción de los agregados. Sin embargo, el promedio obtenido demuestra que los materiales de la cantera Chillico Huaycco poseen un desempeño favorable para la elaboración de concreto estructural. Por consiguiente, se concluye que los agregados provenientes de la cantera Chillico Huaycco cumplen adecuadamente las condiciones requeridas para la producción de concreto diseñado mediante el método ACI 211.1.

Discusión para lograr el objetivo específico 3

El tercer objetivo específico consistió en desarrollar un modelo predictivo basado en redes neuronales artificiales para estimar la resistencia a compresión del concreto considerando las proporciones de mezcla y las propiedades de los materiales. Los resultados obtenidos evidencian que la red neuronal artificial logró establecer una relación adecuada entre las variables de entrada y la resistencia a compresión del concreto. Los gráficos de entrenamiento, validación y prueba muestran una convergencia progresiva de las funciones de pérdida (MSE, MAE y RMSE), indicando que el algoritmo fue capaz de aprender los patrones presentes en la base de datos sin presentar problemas significativos de divergencia.

Asimismo, los diagramas de dispersión entre valores reales y predichos muestran coeficientes de determinación superiores a 0.82 tanto en entrenamiento, validación como en prueba, alcanzando valores cercanos a 0.85 en algunos escenarios. Estos resultados indican una correlación fuerte entre las predicciones generadas por la red neuronal y los resultados

experimentales de resistencia a compresión del concreto.

Los histogramas de residuos muestran distribuciones aproximadamente centradas alrededor de cero, lo cual evidencia la ausencia de sesgos sistemáticos importantes en las predicciones. Del mismo modo, los diagramas de caja indican que la mayoría de los errores se encuentran dentro de rangos aceptables para aplicaciones de ingeniería civil.

Los resultados obtenidos son consistentes con las investigaciones desarrolladas por Khan et al. (2023), Naved et al. (2024), Hosseinzadeh et al. (2024) y Mouawad et al. (2025), quienes reportaron que las redes neuronales artificiales poseen una elevada capacidad para modelar relaciones no lineales entre las características de los materiales constituyentes del concreto y su resistencia mecánica.

Por lo tanto, se considera que el objetivo específico 3 fue cumplido satisfactoriamente, debido a que se logró implementar un modelo predictivo funcional con capacidad adecuada para estimar la resistencia a compresión del concreto.

Discusión para lograr el objetivo específico 4

El cuarto objetivo específico consistió en comparar la resistencia a compresión del concreto obtenida mediante el método ACI 211.1 y el modelo de redes neuronales artificiales. Los resultados muestran diferencias relativamente pequeñas entre los valores reales y las predicciones generadas por la red neuronal. En la muestra de evaluación se observan errores porcentuales comprendidos aproximadamente entre 2 % y 18 %, siendo la mayoría inferiores al 10 %.

La comparación entre los valores reales y predichos evidencia que la red neuronal reproduce adecuadamente la tendencia general de la resistencia a compresión obtenida mediante los diseños de mezcla desarrollados bajo los lineamientos del método ACI 211.1. Si bien existen algunas diferencias puntuales, estas se mantienen dentro de márgenes razonables para aplicaciones de predicción en ingeniería.

Desde una perspectiva práctica, el método ACI 211.1 continúa siendo una herramienta fundamental para el diseño de mezclas; sin embargo, la red neuronal artificial permite obtener estimaciones rápidas de la resistencia a compresión sin necesidad de realizar ensayos físicos preliminares para cada combinación de materiales, constituyéndose en una herramienta complementaria de apoyo a la toma de decisiones.

Los resultados coinciden con los trabajos de Aristizábal e Intor (2023), Bernilla (2024) y Del Águila y Flores (2024), quienes concluyen que las redes neuronales artificiales pueden alcanzar niveles de precisión comparables a los métodos tradicionales de predicción de resistencia del concreto.

En consecuencia, se considera que el objetivo específico 4 también fue alcanzado, ya que la comparación realizada demuestra que las predicciones obtenidas mediante la red neuronal presentan un comportamiento consistente respecto a los resultados obtenidos mediante el método ACI 211.1.

Conclusiones

1. Se determinó que los agregados provenientes de la cantera Chillico Huaycco cumplen las condiciones técnicas para la elaboración de concreto estructural mediante el método ACI 211.1. Las resistencias a compresión obtenidas variaron entre 227.20 y 359.10 kg/cm², con un promedio de 270.74 kg/cm², superando en aproximadamente un 28.9 % la resistencia de diseño de 210 kg/cm². Estos resultados evidencian que las propiedades físicas y mecánicas de los agregados permitieron desarrollar concretos con un comportamiento resistente superior al requerido para el diseño estructural.
2. Se comprobó que el procedimiento de diseño de mezclas establecido por el método ACI 211.1 permitió obtener dosificaciones técnicamente adecuadas para las condiciones de los materiales utilizados. La totalidad de las probetas ensayadas alcanzó resistencias superiores al valor de diseño, demostrando que la selección de la relación agua-cemento, el contenido de cemento y las proporciones de los agregados garantizaron un desempeño mecánico satisfactorio y un adecuado control de calidad durante la elaboración del concreto.
3. Se desarrolló satisfactoriamente un modelo predictivo basado en una red neuronal artificial tipo Perceptrón Multicapa (MLP), el cual logró representar adecuadamente la relación no lineal existente entre las variables de entrada y la resistencia a compresión del concreto. Los coeficientes de determinación superiores a 0.836 obtenidos en las etapas de entrenamiento, validación y prueba, junto con la convergencia de las métricas MSE, RMSE y MAE y la distribución aproximadamente centrada de los residuos, evidencian que el modelo presentó una adecuada capacidad de aprendizaje, estabilidad y generalización para estimar la resistencia del concreto.
4. La comparación entre los resultados obtenidos mediante el método ACI 211.1 y las predicciones generadas por la red neuronal artificial demostró una elevada concordancia entre ambos procedimientos. Los errores porcentuales oscilaron aproximadamente entre 2 % y 18 %, siendo la mayoría inferiores al 10 %, lo que confirma que la red neuronal reproduce de manera confiable el comportamiento resistente del concreto.

Recomendaciones

1. Se recomienda ampliar la base de datos utilizada para el entrenamiento de las redes neuronales artificiales, incorporando un mayor número de diseños de mezcla, diferentes tipos de agregados, aditivos y condiciones ambientales, con la finalidad de incrementar la capacidad de generalización y la precisión predictiva del modelo.
2. Se recomienda evaluar y comparar el desempeño de otros modelos de inteligencia artificial, como Random Forest, XGBoost, Support Vector Machine (SVM) o redes neuronales profundas (Deep Learning), con el propósito de determinar el algoritmo que ofrezca mejores resultados en la estimación de la resistencia a compresión del concreto.
3. Se recomienda implementar el modelo desarrollado como una herramienta de apoyo para laboratorios de materiales, empresas constructoras y entidades académicas, a fin de estimar de manera rápida y confiable la resistencia a compresión del concreto, reduciendo tiempos de evaluación y optimizando el proceso de diseño de mezclas sin reemplazar los ensayos experimentales establecidos por la normativa vigente..
4. Se recomienda validar el modelo de red neuronal artificial desarrollado mediante nuevos ensayos experimentales de resistencia a compresión, utilizando mezclas de concreto elaboradas con agregados de la cantera Chillico Huaycco, con la finalidad de verificar su capacidad predictiva frente a datos no utilizados durante las etapas de entrenamiento, validación y prueba.

REFERENCIAS

- ACI Committee 211. (2022). *ACI 211.1-22: Standard Practice for Selecting Proportions for Normalweight Concrete*. American Concrete Institute. Farmington Hills, MI.
- American Concrete Institute. (2009). *ACI PRC-211.1-91: Standard Practice for Selecting Proportions for Normal, Heavyweight, and Mass Concrete*. American Concrete Institute.
- Aristizaval Albarran, C. D., & Intor Villatty, K. d. A. (2023). *Predicción de la resistencia a la compresión de concreto de 210 kg/cm² y 175 kg/cm² con redes neuronales artificiales, Cajamarca 2022* [Tesis de Ingeniería Civil]. Universidad Privada del Norte.
- ASTM International. (2020). *ASTM C143/C143M: Standard Test Method for Slump of Hydraulic-Cement Concrete*. ASTM International.
- ASTM International. (2023a). *ASTM C33/C33M: Standard Specification for Concrete Aggregates*. ASTM International.
- ASTM International. (2023b). *ASTM C39/C39M: Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens*. ASTM International.
- Bernilla Rodriguez, D. H. (2024). *Predicción de la resistencia a la compresión del concreto mediante redes neuronales artificiales* [Tesis de Ingeniería Civil]. Universidad Católica Santo Toribio de Mogrovejo.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Chou, J.-S., Chiu, C.-K., Farfoura, M., & Al-Taharwa, I. (2011). Optimizing the prediction accuracy of concrete compressive strength based on a comparison of data-mining techniques. *Journal of Computing in Civil Engineering*, 25(3), 242-253. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000088](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000088)
- Del Aguila Vela, D. A., & Flores Castillo, K. E. (2024). *Redes neuronales artificiales para el modelado de la resistencia a la compresión de un concreto $f'c=210$ kg/cm². San Martín 2024* [Tesis de Ingeniería Civil]. Universidad César Vallejo.
- Díaz Tello, M. H. (2017). *Uso de las redes neuronales artificiales en el modelado del ensayo de resistencia a compresión de concreto de construcción según la norma ASTM C39/C39M* [Tesis de Ingeniería Civil]. Universidad Nacional de Cajamarca.
- Fu, H., et al. (2025). Prediction of Compressive Strength of Concrete Using Interpretable Machine Learning Frameworks. *Materials*, 18(21), 5009. <https://doi.org/10.3390/ma18215009>

- Géron, A. (2022). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (3.^a ed.). O'Reilly Media.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning* (2.^a ed.). Springer.
- Haykin, S. (2009). *Neural Networks and Learning Machines* (3.^a ed.). Prentice Hall.
- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la investigación* (6.^a ed.). McGraw-Hill Education.
- Hosseinzadeh, M., Samadvand, H., & Hosseinzadeh, A. (2024a). Concrete Strength and Durability Prediction Through Deep Learning and Artificial Neural Networks. *Frontiers of Structural and Civil Engineering*, 18, 1540-1555. <https://doi.org/10.1007/s11709-024-1124-9>
- Hosseinzadeh, M., et al. (2024b). Concrete strength and durability prediction through deep learning and artificial neural network models. *Frontiers of Structural and Civil Engineering*. <https://doi.org/10.1007/s11709-024-1124-9>
- Khan, A. Q., et al. (2023). Optimized Artificial Neural Network Model for Accurate Prediction of Concrete Compressive Strength. *Results in Engineering*, 18, 101092. <https://doi.org/10.1016/j.rineng.2023.101092>
- Kosmatka, S. H., & Wilson, M. L. (2016). *Design and Control of Concrete Mixtures* (16.^a ed.). Portland Cement Association.
- Kumar, R., et al. (2024). Machine and Deep Learning Methods for Concrete Strength Prediction: A Comprehensive Review. *Applied Soft Computing*.
- Loayza Cáceres, F., & Ramos Butrón, Á. G. (2023). *Uso de redes neuronales artificiales para determinar una nueva alternativa de método de diseño de mezcla de concreto de resistencias convencionales en la ciudad de Arequipa* [Tesis de Ingeniería Civil]. Universidad Católica de Santa María.
- Lupaca Lopez, E. H., & Quispe Huacasi, L. A. (2022). *Eficacia de las redes neuronales artificiales RNA en la predicción de la resistencia a compresión y trabajabilidad del concreto ligero con poliestireno expandido modificado* [Tesis de Ingeniería Civil]. Universidad Nacional del Altiplano.
- Matich, E. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Editorial Universitaria.
- Mehta, P. K., & Monteiro, P. J. M. (2014). *Concrete: Microstructure, Properties, and Materials* (4.^a ed.). McGraw-Hill Education.
- Ministerio de Vivienda, Construcción y Saneamiento. (2023). *Reglamento Nacional de Edificaciones*. Consultado el 30 de julio de 2026, desde <https://www.gob.pe/vivienda>
- Mouawad, F., et al. (2025). Predicting Compressive Strength of Sustainable Concrete Using Machine Learning and Artificial Neural Networks. *Modelling*, 5(3), 56. <https://doi.org/10.3390/modelling5030056>

- Naciones Unidas. (2015). *Transformar nuestro mundo: la Agenda 2030 para el Desarrollo Sostenible*. Consultado el 30 de julio de 2026, desde <https://sdgs.un.org/es/2030agenda>
- Naved, M., et al. (2024). Prediction of Concrete Compressive Strength Using Deep Neural Networks and Hyperparameter Optimization. *Cogent Engineering*, 11(1), 2297491. <https://doi.org/10.1080/23311916.2023.2297491>
- Neville, A. M. (2011). *Properties of Concrete* (5.^a ed.). Pearson.
- Wang, Z., Sun, T., Sun, Y., & Liu, N. (2025). Evaluating the strength properties of high-performance concrete in the form of ensemble and hybrid models using deep learning techniques. *Scientific Reports*, 15(1), 25453. <https://doi.org/10.1038/s41598-025-10860-y>
- Yeh, I.-C. (1998). Modeling of strength of high-performance concrete using artificial neural networks. *Cement and Concrete Research*, 28(12), 1797-1808. [https://doi.org/10.1016/S0008-8846\(98\)00165-3](https://doi.org/10.1016/S0008-8846(98)00165-3)
- Zhang, Y., et al. (2025). Prediction of High-Performance Concrete Compressive Strength Using Tree-Augmented Neural Network Prediction. *Engineering Applications of Artificial Intelligence*. <https://doi.org/10.1016/j.engappai.2025.110869>
- Zhang, Y., Wang, X., & Li, H. (2023). Prediction of Concrete Compressive Strength Using Deep Neural Networks. *Construction and Building Materials*, 376, 131001. <https://doi.org/10.1016/j.conbuildmat.2023.131001>

ANEXOS

3.3 Panel fotográfico

3.3.1 Diseño de mezcla

Figura 42
Diseño de mezcla



Nota. Elaboración propia pesando la probeta.

Figura 43
Pesando los materiales



Nota. Elaboración propia pesando el molde.

3.3.2 Cuarteo

Figura 44
Cuarteo del agregado grueso



Nota. Elaboración propia de cuarteo del material.

Figura 45
Cuarteo de la piedra chancada



Nota. Elaboración propia cuarteo de piedra chancada.

3.3.3 Dosificación

Figura 46
Pesando el agregado



Nota. Elaboración propia pesando el agregado fino.

Figura 47
Insumos para la mezcla



Nota. Elaboración propia pesando los materiales.

3.3.4 Granulometría

Figura 48
Granulometría



Nota. Elaboración propia realizando granulometría.

3.3.5 Absorción y gravedad específica

Figura 49
Curado de las probetas



Nota. Elaboración propia curando las probetas .

3.3.6 Probetas

Figura 50
Probetas



Nota. Elaboración propia curando las probetas.

3.3.7 Rotura de probetas


Figura 51
Rotura de probetas



Nota. Elaboración propia rompiendo las probetas.

3.4 Ubicación distrito de Ayacucho

Figura 52
Área de estudio



Nota. Elaboración propia.

3.5 Datos de entrada para la red neuronal artificial

Tabla 34
Parámetros de entrada parte1 a la RNA

E1	E2	E3	E4	E5	E6	E7	E8	E9	E10	E11	E12
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87

[illegible]

Nota: Elaboración propia

Tabla 35
Parámetros de entrada parte 2 a la RNA

E13	E14	E15	E16	E17	E18	E19	E20	E21	S1
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	187.54
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	206.32
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	215.26
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	220.27
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	189.38
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	192.55
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	201.89
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	196.13
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	195.91
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	202.93
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	192.76
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	216.86
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	214.51
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	203.18
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	212.62
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	229.25
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	190.95
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	230.49
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.2
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.1
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	219.6
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	224.31
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	228.04
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	230.72
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.79
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	225.8
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	225.83
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.08
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	232.59
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	244.84
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	260.85
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	255.14
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	261.81
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	267.31
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	253.76
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	262.78
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	266.75

Nota: Elaboración propia

Tabla 36
Parámetros de entrada parte 3 a la RNA

[illegible]

0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87

Nota: Elaboración propia

Tabla 37
Parámetros de entrada parte 4 a la RNA

E13	E14	E15	E16	E17	E18	E19	E20	E21	S1
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	187.54
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	206.32
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	215.26
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	220.27
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	189.38
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	192.55
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	201.89
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	196.13
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	195.91
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	202.93
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	192.76
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	216.86
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	214.51

5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	203.18
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	212.62
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	229.25
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	190.95
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	230.49
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.2
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.1
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	219.6
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	224.31
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	228.04
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	230.72
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.79
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	225.8
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	225.83
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.08
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	232.59
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	244.84
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	260.85
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	255.14
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	261.81
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	267.31
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	253.76
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	262.78
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	266.75
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	258.64
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	249.8
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	244
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	252.61
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	255.76
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	271.6
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	261.85
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	255.1
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	284.78
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	231.71
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	280.55
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	264.26
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	293.59
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	287.66

Nota: Elaboración propia

[illegible]

0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87
0.75	2.98	7.75	1699.96	1390.12	1907.48	1563.1	3.15	2.51	2.57	2.67	1.87

Nota: Elaboración propia

Tabla 39
Parámetros de entrada parte 6 a la RNA

E13	E14	E15	E16	E17	E18	E19	E20	E21	S1
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	187.54
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	206.32
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	215.26
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	220.27
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	189.38
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	192.55
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	201.89
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	196.13
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	195.91
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	202.93
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	192.76

5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	216.86
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	214.51
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	203.18
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	212.62
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	229.25
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	190.95
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	230.49
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.2
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.1
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	219.6
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	224.31
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	228.04
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	230.72
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.79
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	225.8
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	225.83
5.59	1.42	0.56	7	210	366.07	775.75	954.33	187.81	227.08
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	232.59
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	244.84
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	260.85
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	255.14
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	261.81
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	267.31
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	253.76
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	262.78
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	266.75
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	258.64
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	249.8
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	244
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	252.61
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	255.76
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	271.6
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	261.85
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	255.1
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	284.78
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	231.71
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	280.55
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	264.26
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	293.59

5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	287.66
5.59	1.42	0.56	14	210	366.07	775.75	954.33	187.81	321.24

Nota: Elaboración propia

ENSAYO DE RESISTENCIA A LA COMPRESIÓN SIMPLE DEL CONCRETO NORMAS ASTM C 39 / MTC E 704 - 2000

PROYECTO DE TESIS:

“COMPARACIÓN DE LA RESISTENCIA A COMPRESIÓN DEL CONCRETO MEDIANTE EL MÉTODO ACI 211.1 Y LAS REDES NEURONALES ARTIFICIALES, AYACUCHO 2025”

TESISTA: AVEL QUIHUI MEJIA

CANTERA: CHILLICO

Nº	FECHA DE MOLDEO	FECHA DE ROTURA	EDAD (Días)	DIÁMETRO DEL TESTIGO (cm)	ÁREA DEL TESTIGO (cm ²)	ALTURA DEL ESPECIMEN (cm)	RELACIÓN	PESO DEL ESPECIM. (kg)	PESO UNITARIO APARENTE (tn/m ³)	LECTURA DIGITAL (kg)	LECTURA CORREGIDA A CALIBRACIÓN (kg)	RESISTENCIA DEL ESPECIMEN (kg/cm ²)	RESISTENCIA DE DISEÑO (kg/cm ²)	% RESISTENCIA
1	28/04/2026	26/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.24	44,791.0	44,736.6	244.0	210.0	116%
2	28/04/2026	26/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.33	38,670.7	38,610.4	280.3	210.0	114%
3	28/04/2026	26/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.39	43,992.9	43,937.5	263.4	210.0	125%
4	28/04/2026	26/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.33	40,843.9	40,885.9	232.9	210.0	110%
5	28/04/2026	26/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.38	39,008.1	38,946.1	258.7	210.0	123%
6	30/04/2026	28/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.38	37,245.7	37,183.9	227.2	210.0	108%
7	30/04/2026	28/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.38	37,245.7	37,183.9	258.5	210.0	123%
8	30/04/2026	28/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.35	39,669.7	39,810.4	308.8	210.0	147%
9	30/04/2026	28/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.36	47,224.3	47,172.5	268.5	210.0	127%
10	30/04/2026	28/05/2026	28	15.21	181.7	30.00	1.09	12.200	2.34	42,911.3	42,855.2	359.1	210.0	171%


RESUMEN DE RESULTADOS DE LOS ENSAYOS DE CERTIFICACIÓN EN EL AGREGADO GRUESO

ESPECIFICACIONES NORMALIZADAS PARA AGREGADOS GRUESOS EN EL CONCRETO BASADO EN LA NTP 400.037				CANTERA CHILICO	
Descripción	Norma referencia	Requisito	Observación	Valores (%)	Condición
REQUISITOS GRANULOMÉTRICOS					
Análisis Granulométrico	NTP 400.012	Tabla 4 NTP 400.037	Para todos los concretos	HUSO 57 (1" a N°4)	Dentro del Rango
SUSTANCIAS NOCIVAS					
Arcilla en terrones y partículas desmenuzables ("friables") en agregados (%)	MTC E 212	$\leq 5.0 \%$	Para todos los concretos (Tabla 2 de la NTP 400.037)	2,9	Dentro del Rango
Materiales más finos que pasan por el tamiz normalizado 75 μ m (N°0, 200) por lavado en agregados.	NTP 400.018	$\leq 1 \%$	Límite NTP 400.037	0,9	Dentro del Rango
		$\leq 1,5 \%$	Si el material N°200 no se araña o si el AF tiene un N°200 inferior al límite permitido.		
Hidratno (Partículas Ligeras $G_c < 2.4$)	MTC E 211	$\leq 5 \%$	Solo en casos de incumplimiento: moderadas (continuamente expuesto a congelación y deshielo en presencia de humedad)	0,3	Dentro del Rango
Ensayo para determinar las partículas livianas en los agregados. - Concón y Lignio (%)	MTC E 211	≤ 0.5	Si la proporción del concreto es : importante	0,0	Dentro del Rango
		≤ 1.0	La eficiencia del concreto no es importante.		
Reactividad agregados (álcali (método químico))	MTC E 217	No reactivo	Para los concretos sujetos permanentemente a la acción de la humedad o contacto con suelos húmedos. (Numeral 19.2 de la NTP 400.037)	INNOCUO	Dentro del Rango
INALTERABILIDAD					
Durabilidad a Sulfato de Magnesio (%)	MTC E 209	$\leq 18 \%$	Para todos los concretos que estarán sujetos a problemas de congelación y deshielo. Puede usarse agregados que no cumplan este requisito siempre que se demuestre que se producirá concreto de la resistencia requerida a satisfacción de las partes. (Tabla 6)	10,9	Dentro del Rango

RESUMEN DE RESULTADOS DE LOS ENSAYOS DE CERTIFICACIÓN EN EL AGREGADO GRUESO

ESPECIFICACIONES NORMALIZADAS PARA AGREGADOS GRUESOS EN EL CONCRETO BASADO EN LA NTP 400.037				CANTERA CHILLICO	
Descripción	Norma referencia	Requisito	Observación	Valores (%)	Controles
INDICE DE RESISTENCIA MECANICA (F'c= 210 kg/cm²)					
Abrasión los Ángeles, (L.A.), al desgaste de los agregados de tamaños mayores de 3/8" (9,5mm) a 1/2" (12,5mm)	MTC E 207	<= 50 %	Para todos los concretos	12	Dentro del Rango
Coficiente de Impacto del Agregado (VIA) (%)	NTP 400.008	<= 30 %	Para todos los concretos	17	Dentro del Rango
Índice de espesor	MTC E 221	<= 50 %	Agregados naturales	9	Dentro del Rango
		<= 35 %	Agregados triturados		Dentro del Rango
CARACTERISTICAS QUIMICAS					
Contenido de Sulfatos, expresado como SO ₃ (%)	NTP 339.177	<= 1,0%	Para todos los concretos	0,022	Dentro del Rango
Contenido de Cloruros, expresado como Cl (%)	NTP 339.178	<= 0,1%	Para todos los concretos	0,002	Dentro del Rango

CURVA GRANULOMÉTRICA



LIMO Y ARCILLA	ARENA			GRAVA		BOLON. +BLOQ.
	FINA	MEDIA	GRUESA	FINA	GRUESA	

RESUMEN DE RESULTADOS DE LOS ENSAYOS DE CERTIFICACIÓN EN EL AGREGADO FINO

ESPECIFICACIONES NORMALIZADAS PARA AGREGADOS FINOS EN EL CONCRETO (Arena) BASADO EN LA NTP 400.037				CANTERA CHILLICO	
Descripción	Norma Referencia	Requisito	Observación	Valores (%)	Condición
REQUISITOS GRANULOMÉTRICOS					
Análisis Granulométrico	NTP 400.012	Tabla 1 NTP 400.037	Cumplimiento del Módulo Granulométrico para lechos los concretos. (Números 5, 1 de la NTP 400.037)	Huso Granulométrico	Se ajusta
Análisis Granulométrico	NTP 400.012	N, fb = < 45%	El agregado fino no debe tener más del 45%, que pasa en alguna malla y retenida en la siguiente malla. (Numeral 5.2 de la NTP 400.037)	Huso Granulométrico	Dentro del Rango
Análisis Granulométrico	NTP 400.012	2.3 mm < x 1.	El módulo de finura no debe ser menor de 2.3 ni mayor de 3.1 (Numeral 5.2 de la NTP 400.037)	3.0	Dentro del Rango
SUSTANCIAS NOCIVAS					
Arcilla en terrones y partículas desmenuzables. (Visibles) en agregados (%)	MTC E 212	<= 3.0 %	Para todos los concretos. (Tabla 2 de la NTP 400.037)		Dentro del Rango
Materiales más finos que pasan por el tamiz normalizado 75 µm (No. 200) para lavado en agregados.	NTP 400.018	<= 3.0 %	Para concretos sujetos a abrasión, arena trarandoada.	2.3	Dentro del Rango
		<= 5.0 %	Para los demás concretos, arena zarandeada.		Dentro del Rango
		<= 5.0 %	Para concretos sujetos a abrasión, el la arena proviene del chancado y el material Pasante por el tamiz No. 200 no ha sido.		Dentro del Rango
		<= 7.0 %	Para los demás concretos, el la arena proviene del chancado y el material Pasante por el tamiz No. 200 no ha sido.		Dentro del Rango
Valoración de minerales arcillosos en las materiales finos por medio del Azul de Metileno	AASHTO TP 57	< 5 mg/g	En caso no cumpla el porcentaje de finos máximo (N°200), verificar además el % de arcilla con el ensayo de metileno. (Numeral 5.3 de la NTP 400.037)	4.5	Dentro del Rango
Análisis granulométrico por medio del Hidrómetro	MTC E 109	< 4 % (2 µm)	En caso no cumpla el porcentaje de finos máximo (N°200), verificar además el valor de Absorción del azul de Metileno. (5.3 de la NTP 400.037)	0.1	Dentro del Rango
Ensayo para determinar las partículas livianas en los agregados. (Cachion y Lignito) (%)	MTC E 211	<= 0.5	Si la seplencia del concreto es importante (Tabla 2 de la NTP 400.037)	0.0	Dentro del Rango
		<= 1.0	Las seplencia del concreto no es importante (Tabla 2 de la NTP 400.037)		Dentro del Rango
	MTC E 217	No reactivo	Para los concretos sujetos permanentemente a la acción de la humedad o contacto con suelos húmedos. (Numeral 5.3 de la NTP 400.037)	NINGUNO	Dentro del Rango
IMPUREZAS ORGÁNICAS					
CONSORCIO VICENTE/MARIO					
Ensayo para determinar cualitativamente las impurezas orgánicas en el agregado fino para concreto.	MTC E 213	Color 1	Ninguna impureza orgánica	Color: 1	Ninguna impureza orgánica
		Color 2	Poca impureza orgánica		
		Color 3	Aceptable		
		Color 4	Con deplorable definición de impurezas orgánicas. Hacer otros pruebas, ya puede hacer a de incrustación azul la muestra de mortero a los 7 días no será menor del 90%.		
		Color 5	Daño para el concreto.		

GRANULOMETRÍAS NORMALIZADAS PARA AGREGADO FINO			CANTERA CHILLICO		
Descripción	Norma Referencia	Requisito	Observación	Valores (%)	Condición
MATERIALIZADO					
Punzilidad o Índice de Aplanamiento (%)	MTC E 210	<= 15	Para todos los concretos que estén sujetos a prestaciones de agregabilidad y durabilidad. El equivalente porcentual que no cumpla este requisito siempre que se demuestre que se producirán concretos de la resistencia requerida y satisfactoria de las obras. (Tabla 5 de la NTP 400.012)	12,0	Dentro del Rango
CARACTERÍSTICAS QUÍMICAS					
Contenido de Sulfatos expresado como SO ₃ (%)	NTP 339.177	<= 1,2%	Para todos los concretos	0,019	Dentro del Rango
Contenido de Cloruros expresados como Cl ⁻ (%)	NTP 339.176	<= 0,1%	Para todos los concretos	0,071	Dentro del Rango

LIMO Y ARCILLA	ARENA			GRAVA		BOLEO Y BLOQUE
	FINA	MEDIA	GRUESA	FINA	GRUESA	

**UNSCH**FACULTAD DE CIENCIAS
AGRARIAS**ACTA DE SUSTENTACIÓN DE TESIS****Bach. AVEL QUIHUI MEJIA****R.D. N° 433-2026-UNSCH-FCA-D**

En la ciudad de Ayacucho, a los diez días del mes de setiembre del año dos mil veintiséis, siendo las dieciséis horas, se reunieron en el auditorio de la Facultad de Ciencias Agrarias, bajo la presidencia del Dr. Felipe Escobar Ramírez Decano de la Facultad de Ciencias Agrarias; los miembros del jurado conformado por el M.Sc. Federico Quicaño Suárez, Dr. Richard Alex Oscco Peceros como asesor, Ing. Orlando Fidel Sulca Castilla y el Mg. Oscar Guido Rivera Ynouye; actuando como secretario de actas el Mtro. Rodolfo Alca Mendoza, para recibir la sustentación de la Tesis titulado: **Comparación de la resistencia a compresión del concreto mediante el método ACI 211.1 y las redes neuronales artificiales, Ayacucho, 2025**, para obtener el Título Profesional de Ingeniero Agrícola, presentado por el Bachiller **AVEL QUIHUI MEJIA**.

El señor Decano previa verificación de los documentos exigidos solicitó se proceda con la sustentación y posterior defensa de la tesis en un periodo de cuarenta y cinco minutos de acuerdo al reglamento de grados y títulos vigente. Terminado la exposición, los miembros del Jurado, formularon sus preguntas, aclaraciones y/o observaciones correspondientes. Luego se invitó a los miembros del jurado pasar a otra aula para la deliberación y calificación del trabajo de tesis, teniendo el siguiente resultado:

Jurado evaluador	Exposición	Respuestas a las preguntas	Generación de conocimiento	Promedio
M.Sc. Federico Quicaño Suárez	15	14	13	14
Dr. Richard Alex Oscco Peceros	16	16	16	16
Ing. Orlando Fidel Sulca Castilla	16	16	16	16
Mg. Oscar Guido Rivera Ynouye	12	13	16	15
PROMEDIO GENERAL				15

Acto seguido se invita a la sustentante y público en general para dar a conocer el resultado final. Firman el acta.


.....
M.Sc. Federico Quicaño Suárez
Presidente


.....
Dr. Richard Alex Oscco Peceros
Asesor


.....
Ing. Orlando Fidel Sulca Castilla
Jurado


.....
Mg. Oscar Guido Rivera Ynouye
Jurado


.....
Mtro. Rodolfo Alca Mendoza
Secretario Docente



UNSCH

FACULTAD DE CIENCIAS
AGRARIAS

CONSTANCIA DE CONTROL DE ORIGINALIDAD DE TRABAJO DE TESIS

El que suscribe, miembro de la comisión de docentes instructores responsables de operativizar, verificar, garantizar y controlar la originalidad de los trabajos de **TESIS** de la Facultad de Ciencias Agrarias, de la Universidad Nacional de San Cristóbal de Huamanga, autorizado por R.D N° 437-2026-UNSCH-FCA-D; hace constar que el trabajo titulado;

Comparación de la resistencia a compresión del concreto mediante el método ACI 211.1 y las redes neuronales artificiales, Ayacucho, 2025

Autor : Avel Quihui Mejia
Asesor : Richard Alex Oscoco Peceros

Ha sido sometido al control de originalidad mediante el software TURNITIN UNSCH, acorde al Reglamento de originalidad de trabajos de tesis, aprobando mediante RCU N°039-2021-UNSCH-CU, arrojando un resultado de ocho por ciento **(8 %)** de índice de similitud, realizado con **depósito de trabajo estándar**.

En consecuencia, se otorga la presente Constancia de Originalidad para los fines pertinentes.

Nota: Se adjunta el resultado con identificador de la entrega: 3041582683.

Ayacucho, 25 de setiembre de 2026


.....
Mtro. Carlos Augusto Castañeda Esquén
Docente Instructor -EPIA

Comparación de la resistencia a compresión del concreto mediante el método ACI 211.1 y las redes neuronales artificiales, Ayacucho, 2025

por Avel Quihui Mejia

Fecha de entrega: 25-sept-2026 01:20a. m. (UTC-0500)

Identificador de la entrega: 3041582683

Nombre del archivo: TIMO_CORREGIDO_-TESIS_AVEL_QUIHUI_MEJIA_FALTA_PASAR_TURNITIN.pdf (37.58M)

Total de palabras: 30869

Total de caracteres: 144009

Comparación de la resistencia a compresión del concreto mediante el método ACI 211.1 y las redes neuronales artificiales, Ayacucho, 2025

INFORME DE ORIGINALIDAD

8%	9%	6%	6%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universidad Nacional de San Cristóbal de Huamanga	2%
	Trabajo del estudiante	
2	repositorio.unsch.edu.pe	1%
	Fuente de Internet	
3	repositorio.uss.edu.pe	1%
	Fuente de Internet	
4	repositorio.utea.edu.pe	1%
	Fuente de Internet	
5	hdl.handle.net	<1%
	Fuente de Internet	
6	www.atlantis-press.com	<1%
	Fuente de Internet	
7	repositorio.ucv.edu.pe	<1%
	Fuente de Internet	
8	repositorio.unap.edu.pe	<1%
	Fuente de Internet	
9	tesisenxarxa.net	<1%
	Fuente de Internet	
10	Journal of Modelling in Management, Volume 7, Issue 2 (2012-06-30)	<1%
	Publicación	
11	Submitted to Docentes	<1%
	Trabajo del estudiante	
12	Submitted to Universidad Privada del Norte	<1%
	Trabajo del estudiante	
13	repositorio.ucsm.edu.pe	<1%
	Fuente de Internet	
14	dspace.unitru.edu.pe	<1%
	Fuente de Internet	
15	Submitted to Blackboard	<1%
	Trabajo del estudiante	
16	researchcommons.waikato.ac.nz	

Fuente de Internet

<1 %

17 buleria.unileon.es

Fuente de Internet

<1 %

18 Submitted to D.A. de Ingeniería Civil

Trabajo del estudiante

<1 %

19 ouci.dntb.gov.ua

Fuente de Internet

<1 %

20 tesis.usat.edu.pe

Fuente de Internet

<1 %

21 repositorioacademico.upc.edu.pe

Fuente de Internet

<1 %

22 www.polodelconocimiento.com

Fuente de Internet

<1 %

23 Submitted to Universidad Europea de Madrid

Trabajo del estudiante

<1 %

24 repositorio.upse.edu.ec

Fuente de Internet

<1 %

25 repositorio.uniscjsa.edu.pe

Fuente de Internet

<1 %

26 repositorio.utc.edu.ec

Fuente de Internet

<1 %

27 Submitted to Universidad Andina del Cusco

Trabajo del estudiante

<1 %

28 Submitted to Universidad Nacional de Ingeniería

Trabajo del estudiante

<1 %

29 ctscafe.pe

Fuente de Internet

<1 %

Excluir citas

Activo

Excluir coincidencias

< 30 words

Excluir bibliografía

Activo

Comparación de la resistencia a compresión del concreto mediante el método ACI 211.1 y las redes neuronales artificiales, Ayacucho 2025

Avel Quihui Mejia. avel.quihui@unsch.edu.pe

Richard Alex Oscoco Peceros. richard.oscco@unsch.edu.pe

Área de investigación: Ingenierías y Ciencias Básicas

Línea de investigación: Gestión y Diseño de Infraestructuras Resistentes y Sustentables

RESUMEN

La resistencia a compresión es una de las propiedades mecánicas más importantes del concreto, debido a que determina su capacidad para soportar cargas estructurales. La presente investigación tuvo como objetivo comparar la resistencia a compresión del concreto obtenida mediante el método ACI 211.1 y la estimada mediante redes neuronales artificiales (RNA) en Ayacucho, 2025.

La investigación fue de enfoque cuantitativo, nivel predictivo y diseño con componente experimental. La unidad de análisis estuvo constituida por las probetas ensayadas para determinar la resistencia a compresión. La población estuvo conformada por 806 resultados de probetas correspondientes a la construcción de la Escuela Profesional de Ingeniería Agrícola, obtenidos de un laboratorio de agregados. Se empleó una muestra censal constituida por los 806 resultados. Como variables de entrada se consideraron el contenido de cemento, agua, agregado fino, agregado grueso, aditivos y relación agua-cemento. Para la predicción se implementó una red neuronal artificial tipo Perceptrón Multicapa (MLP), mediante aprendizaje supervisado. El desempeño se evaluó mediante MSE,

RMSE, MAE y coeficiente de determinación (R^2).

Los resultados mostraron un desempeño predictivo con valores de R^2 superiores al 83.6 % y errores reducidos respecto a los valores experimentales. Asimismo, el ANOVA evidenció diferencias estadísticamente significativas ($P < 0,05$).

Se concluye que las redes neuronales artificiales constituyen una herramienta eficiente para estimar la resistencia a compresión del concreto, contribuyendo a reducir tiempos de evaluación y apoyar la toma de decisiones en ingeniería civil.

Palabras clave: resistencia a compresión, concreto, ACI 211.1, redes neuronales artificiales, aprendizaje automático, diseño de mezclas.

ABSTRACT

Compressive strength is one of the most important mechanical properties of concrete, as it determines its ability to withstand structural loads. The objective of this research was to compare the compressive strength of concrete obtained using the ACI 211.1 method with that estimated using artificial neural networks (ANN) in Ayacucho, 2025.

The research followed a quantitative approach, with a predictive level and a design including an experimental component. The unit of analysis consisted of concrete specimens tested to determine their compressive strength. The population consisted of 806 concrete specimen test results corresponding to the construction of the Professional School of Agricultural Engineering, obtained from an aggregates laboratory. A census sample comprising all 806 results was used. The input variables included cement content, water, fine aggregate, coarse aggregate, admixtures, and water-cement ratio. For prediction, a Multilayer Perceptron (MLP) artificial neural network was implemented using supervised learning. Model performance was evaluated using MSE, RMSE, MAE, and the coefficient of determination (R^2).

The results showed good predictive performance, with R^2 values above 83.6 % and low errors compared with the experimental values. Furthermore, ANOVA showed statistically significant differences ($P < 0,05$).

It is concluded that artificial neural networks constitute an efficient tool for estimating the compressive strength of concrete, contributing to reducing evaluation time and supporting decision-making in civil engineering.

Keywords: concrete, compressive strength, artificial neural networks, ACI.

I. INTRODUCCIÓN

El concreto es el material de construcción más utilizado a nivel mundial debido a su resistencia, durabilidad y versatilidad en obras de infraestructura y edificaciones. Su desempeño estructural depende, en gran

medida, de un diseño adecuado de la mezcla y de la calidad de los materiales empleados. En los últimos años, la incorporación de herramientas computacionales e inteligencia artificial ha permitido optimizar la predicción de propiedades mecánicas, especialmente la resistencia a compresión, mejorando la eficiencia en el diseño del concreto (Neville, 2011).

La presente investigación contribuye principalmente al Objetivo de Desarrollo Sostenible 9 (Industria, innovación e infraestructura) al promover la aplicación de métodos innovadores para optimizar el diseño del concreto mediante redes neuronales artificiales. Asimismo, aporta al ODS 11 (Ciudades y comunidades sostenibles), al favorecer el desarrollo de infraestructuras más seguras, eficientes y resilientes mediante el uso de tecnologías que mejoran la calidad y el desempeño de los materiales de construcción (Naciones Unidas, 2015).

En Estados Unidos, la dosificación del concreto mediante el método ACI 211.1 continúa siendo una de las metodologías más empleadas para el diseño de mezclas debido a su confiabilidad y amplia validación experimental. Sin embargo, investigaciones recientes incorporan modelos de aprendizaje automático y redes neuronales artificiales para estimar la resistencia a compresión con mayor precisión, reduciendo costos experimentales y optimizando el proceso de diseño de mezclas de concreto (Zhang et al., 2023).

En el Perú, el diseño de mezclas de concreto se realiza principalmente mediante procedimientos normados, como el método ACI 211.1, debido a su confiabilidad para alcanzar la resistencia especificada. Sin embargo, el creciente desarrollo de la inteligencia artificial ha impulsado

investigaciones que incorporan redes neuronales artificiales para mejorar la predicción de la resistencia a compresión, optimizar el consumo de materiales y reducir los costos asociados a los ensayos experimentales (Ministerio de Vivienda, Construcción y Saneamiento, 2023).

En Ayacucho, la producción de concreto depende en gran medida de los agregados provenientes de canteras locales, como Chillico Huaycco, cuyas propiedades físicas y mecánicas influyen directamente en la resistencia del concreto. No obstante, son escasas las investigaciones que comparan el diseño convencional mediante el método ACI 211.1 con modelos predictivos basados en redes neuronales artificiales, limitando la incorporación de tecnologías de inteligencia artificial para optimizar el diseño de mezclas adaptadas a las condiciones locales (Ministerio de Vivienda, Construcción y Saneamiento, 2023).

La resistencia a compresión del concreto constituye una de las propiedades mecánicas más importantes para garantizar la seguridad y durabilidad de las estructuras. Sin embargo, la variabilidad en las características de los agregados, las proporciones de mezcla y las condiciones de fabricación pueden ocasionar diferencias significativas entre la resistencia diseñada y la obtenida experimentalmente. Además, los métodos convencionales de dosificación presentan limitaciones para modelar relaciones complejas entre múltiples variables, lo que afecta la precisión en la estimación de la resistencia del concreto (Neville, 2011).

La presente investigación busca comparar la resistencia a compresión del concreto obtenida mediante el método ACI 211.1 y un modelo basado en redes neuronales artificiales, con el propósito de determinar si las técnicas de inteligencia artificial ofrecen una mayor precisión en la predicción del comportamiento mecánico del concreto. De no desarrollarse este estudio, continuará predominando el uso exclusivo de métodos tradicionales, desaprovechando herramientas computacionales capaces de optimizar el diseño de mezclas, reducir costos experimentales y mejorar la calidad y confiabilidad de las estructuras de concreto (Zhang et al., 2023).

La investigación contribuirá al fortalecimiento del conocimiento científico sobre la aplicación del método ACI 211.1 y de las redes neuronales artificiales en la predicción de la resistencia a compresión del concreto. Asimismo, ampliará la evidencia sobre el uso de modelos de inteligencia artificial en ingeniería de materiales, proporcionando información que podrá servir como referencia para futuras investigaciones relacionadas con el diseño óptimo de mezclas de concreto (ACI Committee 211, 2022).

Desde el punto de vista práctico, los resultados permitirán determinar si las redes neuronales artificiales constituyen una alternativa eficiente para estimar la resistencia a compresión del concreto, reduciendo el número de ensayos experimentales, optimizando el diseño de mezclas y favoreciendo la toma de decisiones en proyectos de ingeniería civil desarrollados con materiales locales.

Cumpliendo con el objetivo general que es comparar la resistencia a compresión del concreto mediante el método ACI 211.1 y las redes neuronales artificiales, utilizando agregados de la cantera Chillico Huaycco, Ayacucho, 2025.

Donde también se cumplieron los objetivos específicos mencionados:

1. Caracterizar las propiedades físicas y mecánicas de los agregados provenientes de la cantera Chillico Huaycco, Ayacucho, 2025.
2. Diseñar una mezcla de concreto utilizando el método ACI 211.1, Ayacucho, 2025.
3. Desarrollar un modelo predictivo basado en redes neuronales artificiales para estimar la resistencia a compresión del concreto, considerando las proporciones de mezcla y las propiedades de los materiales, Ayacucho, 2025.

II. METODOLOGÍA

2.1. Tipo de investigación

Según Hernández Sampieri et al. (2014), Se considera que este tipo de investigación aplicada se define como condiciones reguladas en las que se altera intencionalmente una o más variables independientes (factores causales) para examinar el impacto de estos cambios en una o más variables dependientes. La investigación es aplicada; ya que, se aplicarán criterios técnicos para el análisis de materiales, la modelación computacional del diseño de mezclas, la validación estructural mediante cálculos precisos y el uso de tecnologías innovadoras como las redes

neuronales, con el objetivo de generar soluciones sostenibles y de impacto positivo para la infraestructura en Ayacucho.

2.2. Nivel de investigación

Según Hernández Sampieri et al. (2014), la presente investigación es de nivel predictivo, debido a que busca estimar la resistencia a compresión del concreto mediante un modelo de red neuronal artificial. Para ello, se emplean como variables de entrada las características de los materiales, propiedades de los agregados, dosificación y edad de ensayo. El modelo es entrenado con datos históricos para identificar las relaciones entre dichas variables y la resistencia observada. Posteriormente, su capacidad predictiva se evalúa mediante los indicadores MSE, MAE, RMSE y R^2 , comparando los valores reales con los valores estimados por el modelo.

2.3. Diseño de investigación

Según Hernández Sampieri et al. (2014), el diseño de la investigación va tener un componente experimental porque va caracterizar, dosificar, fabricar y realizar ensayo de concreto para colaborar los resultados de la red neuronal artificial y también va tener un componente computacional porque va entrenar, validar y realizar la prueba para el modelo de RNA.

2.4. Población

Según Hernández Sampieri et al. (2014), La población está constituida por las probetas o resultados de resistencia a compresión correspondientes al concreto utilizado en la edificación de la Escuela Profesional de Ingeniería Agrícola. De este conjunto se contó con un total de 806 resultados de roturas de concreto, los cuales constituyeron la muestra

utilizada para alimentar y entrenar la red neuronal artificial. En esta investigación se ha considerado la información correspondiente a la construcción de la Escuela Profesional de Ingeniería Agrícola, donde se trabajó con agregados provenientes de la cantera chillico. Por lo tanto, los datos de las 806 probetas fueron utilizados como información histórica para que la red neuronal artificial pudiera identificar la relación existente entre las características de los materiales, la dosificación del concreto y la resistencia obtenida.

2.5. Muestra

Según Hernández Sampieri et al. (2014), La muestra estuvo constituida por la totalidad de los 806 resultados de ensayos de resistencia a compresión del concreto correspondientes a la construcción de la Escuela Profesional de Ingeniería Agrícola. Debido a que se empleó la totalidad de los registros disponibles que conforman la población de estudio, se consideró una muestra censal, por lo que el tamaño de la muestra fue de $n = 806$ resultados.

Estos registros fueron utilizados como datos históricos para el desarrollo del modelo de red neuronal artificial, permitiendo identificar la relación entre las características de los materiales, la dosificación del concreto y la resistencia a compresión obtenida.

2.6. Técnicas

Para el desarrollo de la presente investigación se emplearon las siguientes técnicas:

1. Recolección de muestras *in situ*

- Extracción directa de agregados finos y gruesos en la cantera de Chillico Huaycco.

- Recolección del agua utilizada para la elaboración de las mezclas de concreto.

2. Experimentación controlada

- Diseño y elaboración de mezclas mediante el método ACI 211.1.
- Registro de las propiedades del concreto, tales como resistencia a la compresión, asentamiento (slump), trabajabilidad y relación agua cemento.



3. Modelado mediante redes neuronales artificiales

- Implementación de un modelo basado en Redes Neuronales Artificiales (RNA) para estimar la resistencia a compresión del concreto.
- Optimización de las proporciones de mezcla y análisis de la relación entre las variables de entrada y la resistencia obtenida.

III. RESULTADOS

3.1. Resultado para el objetivo específico 1 y 2

Los agregados utilizados en la presente investigación procedieron de la cantera Chillico Huaycco, ubicada en la provincia de Huamanga, departamento de Ayacucho. La caracterización física y mecánica permitió verificar la aptitud de los materiales para la elaboración de concreto estructural mediante el método ACI 211.1. Como resultado de la dosificación de mezclas y posterior ensayo de compresión, se obtuvieron resistencias comprendidas entre 227.20 y 359.10 kg/cm², con valores individuales de 244.00, 280.30, 263.35, 232.94, 258.70, 227.20, 258.50, 308.80, 268.49 y 359.10 kg/cm².

Tabla 33.

Resistencia a compresión obtenida con agregados de la cantera Chillico Huaycco.

Muestra	Resistencia (kg/cm ²)
1	244.00
2	280.30
3	263.35
4	232.94
5	258.70
6	227.20
7	258.50
8	308.80
9	268.49
10	359.10

El promedio de resistencia obtenido fue de aproximadamente 270.74 kg/cm², valor superior a la resistencia de diseño de 210 kg/cm² considerado en el método ACI 211.1.

3.2. Resultado para el objetivo específico 3

Se desarrolló una red neuronal artificial tipo Perceptrón Multicapa (MLP), conformada por 21 variables de entrada y una variable de salida. El modelo permitió estimar la resistencia a compresión. En entrenamiento obtuvo un $R^2 = 0,839$, en validación alcanzó un $R^2 = 0,836$ y en prueba obtuvo un $R^2 = 0,846$. Las métricas mostraron un comportamiento estable. La RNA presentó adecuada capacidad de aprendizaje y generalización para datos no utilizados en entrenamiento.

Tabla 26

Métricas de evaluación del modelo de red neuronal artificial

Métrica	Conjunto de datos			Interpretación
	Entrenamiento	Validación	Prueba	
MSE	0.1234	0.1456	0.1567	Error cuadrático medio bajo y estable
MAE	0.2856	0.3123	0.3254	Error absoluto medio aceptable
RMSE	0.3512	0.3816	0.3959	Error estándar consistente
R^2	0.839	0.836	0.846	Excelente capacidad predictiva

Nota. Elaboración propia con python.

3.3. Resultado para el objetivo específico 4

Se compararon los valores reales de resistencia con las predicciones obtenidas mediante la RNA. Los resultados mostraron una adecuada concordancia entre los valores experimentales y los predichos. Los errores porcentuales estuvieron aproximadamente entre el 2 % y el 18 %. La mayoría de los errores fueron inferiores al 10 %. La RNA reprodujo la tendencia de la resistencia obtenida con las mezclas diseñadas mediante ACI 211.1, mostrando utilidad como herramienta predictiva complementaria.

superior al requerido para el diseño estructural.

Figura 41
Regresión para 300 épocas




Tabla 31
Tabla de resultados para iteración de 200 épocas

Muestras	Valor real	Predicción	Error	Error (%)
Muestra 1	244.00	266.206	-22.2061	9.10
Muestra 2	280.00	263.476	16.8231	6.00
Muestra 3	263.35	221.215	42.134	15.99
Muestra 4	232.94	230.16	2.77	1.1
Muestra 5	258.70	257.104	1.59	0.61
Muestra 6	227.20	257.1044	-29.9	13.16
Muestra 7	258.50	239.119	19.38	7.49
Muestra 8	308.80	325.95	-17.15	5.55
Muestra 9	268.49	276.59	-8.10	3.00
Muestra 10	359.10	348.728	10.37	2.88

Nota: Elaboración propia

IV. CONCLUSIONES

1. Se determinó que los agregados provenientes de la cantera Chillico Huaycco cumplen las condiciones técnicas para la elaboración de concreto estructural mediante el método ACI 211.1. Las resistencias a compresión obtenidas variaron entre 227.20 y 359.10 kg/cm², con un promedio de 270.74 kg/cm², superando en aproximadamente un 28.9 % la resistencia de diseño de 210 kg/cm². Estos resultados evidencian que las propiedades físicas y mecánicas de los agregados permitieron desarrollar concretos con un comportamiento resistente

2. Se comprobó que el método ACI 211.1 permitió obtener dosificaciones adecuadas para los materiales utilizados. Todas las probetas alcanzaron resistencias superiores a la de diseño, evidenciando un adecuado desempeño mecánico y control de calidad del concreto.

3. Se desarrolló satisfactoriamente un modelo predictivo basado en una red neuronal artificial tipo Perceptrón Multicapa (MLP), capaz de representar la relación no lineal entre las variables de entrada y la resistencia a compresión del concreto. Los coeficientes de determinación superiores a 0.836, junto con la convergencia de las métricas MSE, RMSE y MAE y la distribución de los residuos, evidencian una adecuada capacidad de aprendizaje, estabilidad y generalización del modelo.

4. La comparación entre los resultados obtenidos mediante el método ACI 211.1 y las predicciones generadas por la red neuronal artificial demostró una elevada concordancia entre ambos procedimientos. Los errores porcentuales oscilaron aproximadamente entre 2 % y 18 %, siendo la mayoría inferiores al 10 %, lo que confirma que la red neuronal reproduce de manera confiable el comportamiento resistente del concreto.

REFERENCIAS

- ACI Committee 211. (2022). *ACI 211.1-22: Standard Practice for Selecting Proportions for Normalweight Concrete*. American Concrete Institute. Farmington Hills, MI.
- American Concrete Institute. (2009). *ACI PRC-211.1-91: Standard Practice for Selecting Proportions for Normal, Heavyweight, and Mass Concrete*. American Concrete Institute.
- Aristizaval Albarran, C. D., & Intor Villatty, K. d. A. (2023). *Predicción de la resistencia a la compresión de concreto de 210 kg/cm² y 175 kg/cm² con redes neuronales artificiales, Cajamarca 2022* [Tesis de Ingeniería Civil]. Universidad Privada del Norte.
- ASTM International. (2020). *ASTM C143/C143M: Standard Test Method for Slump of Hydraulic-Cement Concrete*. ASTM International.
- ASTM International. (2023a). *ASTM C33/C33M: Standard Specification for Concrete Aggregates*. ASTM International.
- ASTM International. (2023b). *ASTM C39/C39M: Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens*. ASTM International.
- Bernilla Rodriguez, D. H. (2024). *Predicción de la resistencia a la compresión del concreto mediante redes neuronales artificiales* [Tesis de Ingeniería Civil]. Universidad Católica Santo Toribio de Mogrovejo.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Chou, J.-S., Chiu, C.-K., Farfoura, M., & Al-Taharwa, I. (2011). Optimizing the prediction accuracy of concrete compressive strength based on a comparison of data-mining techniques. *Journal of Computing in Civil Engineering*, 25(3), 242-253. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000088](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000088)
- Del Aguila Vela, D. A., & Flores Castillo, K. E. (2024). *Redes neuronales artificiales para el modelado de la resistencia a la compresión de un concreto $f'c=210$ kg/cm². San Martín 2024* [Tesis de Ingeniería Civil]. Universidad César Vallejo.
- Díaz Tello, M. H. (2017). *Uso de las redes neuronales artificiales en el modelado del ensayo de resistencia a compresión de concreto de construcción según la norma ASTM C39/C39M* [Tesis de Ingeniería Civil]. Universidad Nacional de Cajamarca.
- Fu, H., et al. (2025). Prediction of Compressive Strength of Concrete Using Interpretable Machine Learning Frameworks. *Materials*, 18(21), 5009. <https://doi.org/10.3390/ma18215009>

- Géron, A. (2022). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow* (3.^a ed.). O'Reilly Media.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning* (2.^a ed.). Springer.
- Haykin, S. (2009). *Neural Networks and Learning Machines* (3.^a ed.). Prentice Hall.
- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la investigación* (6.^a ed.). McGraw-Hill Education.
- Hosseinzadeh, M., Samadvand, H., & Hosseinzadeh, A. (2024a). Concrete Strength and Durability Prediction Through Deep Learning and Artificial Neural Networks. *Frontiers of Structural and Civil Engineering*, 18, 1540-1555. <https://doi.org/10.1007/s11709-024-1124-9>
- Hosseinzadeh, M., et al. (2024b). Concrete strength and durability prediction through deep learning and artificial neural network models. *Frontiers of Structural and Civil Engineering*. <https://doi.org/10.1007/s11709-024-1124-9>
- Khan, A. Q., et al. (2023). Optimized Artificial Neural Network Model for Accurate Prediction of Concrete Compressive Strength. *Results in Engineering*, 18, 101092. <https://doi.org/10.1016/j.rineng.2023.101092>
- Kosmatka, S. H., & Wilson, M. L. (2016). *Design and Control of Concrete Mixtures* (16.^a ed.). Portland Cement Association.
- Kumar, R., et al. (2024). Machine and Deep Learning Methods for Concrete Strength Prediction: A Comprehensive Review. *Applied Soft Computing*.
- Loayza Cáceres, F., & Ramos Butrón, Á. G. (2023). *Uso de redes neuronales artificiales para determinar una nueva alternativa de método de diseño de mezcla de concreto de resistencias convencionales en la ciudad de Arequipa* [Tesis de Ingeniería Civil]. Universidad Católica de Santa María.
- Lupaca Lopez, E. H., & Quispe Huacasi, L. A. (2022). *Eficacia de las redes neuronales artificiales RNA en la predicción de la resistencia a compresión y trabajabilidad del concreto ligero con poliestireno expandido modificado* [Tesis de Ingeniería Civil]. Universidad Nacional del Altiplano.
- Matich, E. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Editorial Universitaria.
- Mehta, P. K., & Monteiro, P. J. M. (2014). *Concrete: Microstructure, Properties, and Materials* (4.^a ed.). McGraw-Hill Education.
- Ministerio de Vivienda, Construcción y Saneamiento. (2023). *Reglamento Nacional de Edificaciones*. Consultado el 30 de julio de 2026, desde <https://www.gob.pe/vivienda>
- Mouawad, F., et al. (2025). Predicting Compressive Strength of Sustainable Concrete Using Machine Learning and Artificial Neural Networks. *Modelling*, 5(3), 56. <https://doi.org/10.3390/modelling5030056>

- Naciones Unidas. (2015). *Transformar nuestro mundo: la Agenda 2030 para el Desarrollo Sostenible*. Consultado el 30 de julio de 2026, desde <https://sdgs.un.org/es/2030agenda>
- Naved, M., et al. (2024). Prediction of Concrete Compressive Strength Using Deep Neural Networks and Hyperparameter Optimization. *Cogent Engineering*, 11(1), 2297491. <https://doi.org/10.1080/23311916.2023.2297491>
- Neville, A. M. (2011). *Properties of Concrete* (5.^a ed.). Pearson.
- Wang, Z., Sun, T., Sun, Y., & Liu, N. (2025). Evaluating the strength properties of high-performance concrete in the form of ensemble and hybrid models using deep learning techniques. *Scientific Reports*, 15(1), 25453. <https://doi.org/10.1038/s41598-025-10860-y>
- Yeh, I.-C. (1998). Modeling of strength of high-performance concrete using artificial neural networks. *Cement and Concrete Research*, 28(12), 1797-1808. [https://doi.org/10.1016/S0008-8846\(98\)00165-3](https://doi.org/10.1016/S0008-8846(98)00165-3)
- Zhang, Y., et al. (2025). Prediction of High-Performance Concrete Compressive Strength Using Tree-Augmented Neural Network Prediction. *Engineering Applications of Artificial Intelligence*. <https://doi.org/10.1016/j.engappai.2025.110869>
- Zhang, Y., Wang, X., & Li, H. (2023). Prediction of Concrete Compressive Strength Using Deep Neural Networks. *Construction and Building Materials*, 376, 131001. <https://doi.org/10.1016/j.conbuildmat.2023.131001>