



UNIVERSIDAD TÉCNICA DE AMBATO

FACULTAD INGENIERÍA CIVIL Y MECÁNICA

CARRERA DE INGENIERÍA CIVIL

Predicción de la resistencia a compresión del hormigón simple usando el modelo Least Absolute Shrinkage and Selection Operator (LASSO)

Trabajo de Titulación, Modalidad trabajo experimental previo a la obtención del
Título de Ingeniero Civil

Autora: Karen Alexandra Mosquera Merchán

Tutora: Ing. Mayra Alexandra Viscaíno Cuzco, Mg.

Ambato – Ecuador

Julio – 2026

APROBACIÓN DEL TUTOR

En mi calidad de tutor del trabajo experimental, previo a la obtención del Título de Ingeniero Civil, con el tema: **“PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL HORMIGÓN SIMPLE USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)”**, elaborado por el estudiante Karen Alexandra Mosquera Merchán, portador de la cédula de ciudadanía número 0504554619, estudiante de la Carrera de Ingeniería Civil de la Facultad de Ingeniería Civil y Mecánica.

Certifico:

- Que el presente trabajo experimental es original de su autor.
- Ha sido revisado cada uno de sus capítulos componentes.
- Está concluido en su totalidad.

Ambato, julio 2026



Ing. Mayra Alexandra Viscaino Cuzco, Mg.

C.C. 1400546303

TUTOR

AUTORÍA DEL TRABAJO DE TITULACIÓN

Yo, **Karen Alexandra Mosquera Merchán**, con C.C. 0504554619 declaro que todos los contenidos y actividades expuestos en el desarrollo del presente trabajo experimental con el tema: **“PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL HORMIGÓN SIMPLE USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)”**, así como también los análisis estadísticos, gráficos, conclusiones y recomendaciones son de mi exclusiva responsabilidad como autor del trabajo experimental, a excepción de las referencias bibliográficas citadas en el mismo. En tal virtud, el contenido, efectos legales y académicos que se desprenden del mismo son de exclusiva responsabilidad del autor.

Ambato, julio 2026



.....
Karen Alexandra Mosquera Merchán

C.C. 0504554619

AUTOR

DERECHOS DE AUTOR

Autorizo a la Universidad Técnica de Ambato, para que haga de este trabajo experimental o parte de él, un documento disponible para su lectura consulta y procesos de investigación, según las normas de la Institución.

Cedo los Derechos en línea patrimoniales de mi trabajo experimental, con fines de difusión pública, además apruebo la reproducción de este documento dentro de las regulaciones de la Universidad, siempre y cuando esta reproducción no suponga una ganancia económica y se realice respetando mis derechos de autor.

Ambato, julio 2026



.....
Mosquera Merchán Karen Alexandra

C.C. 0504554619


AUTOR

APROBACIÓN DEL TRIBUNAL DE GRADO

Los miembros del Tribunal de Grado aprueban el informe del trabajo experimental, realizado por el estudiante **Karen Alexandra Mosquera Merchán**, de la Carrera de Ingeniería Civil bajo el tema: **“PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN DEL HORMIGÓN SIMPLE USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)”**, Modalidad trabajo experimental.

Ambato, julio 2026


Para constancia firma:



Ing. Ruth Lorena Pérez Maldonado, Mg.

C.C. 1710320332

MIEMBRO CALIFICADOR



Ing. Milton Rodrigo Aldás Sánchez, Ph.D.

C.C. 1801628155

MIEMBRO CALIFICADOR

ÍNDICE GENERAL DE CONTENIDOS

PORTADA.....	i
APROBACIÓN DEL TUTOR	ii
AUTORÍA DEL TRABAJO DE TITULACIÓN	iii
DERECHOS DE AUTOR	iv
APROBACIÓN DEL TRIBUNAL DE GRADO	v
ÍNDICE GENERAL DE CONTENIDOS	vi
ÍNDICE DE FIGURAS	ix
ÍNDICE DE TABLAS	x
ÍNDICE DE ANEXOS	xii
SIGLAS, ACRÓNIMOS Y ABREVIATURAS.....	xiii
RESUMEN EJECUTIVO	xiv
ABSTRACT	xv
CAPÍTULO I.- MARCO TEÓRICO.....	1
I. JUSTIFICACIÓN	1
II. ANTECEDENTES INVESTIGATIVOS	3
III. OBJETIVOS.....	6
A. OBJETIVO GENERAL.....	6
B. OBJETIVOS ESPECÍFICOS	6
CAPÍTULO II.- METODOLOGÍA.....	7
I. EQUIPOS Y MATERIALES	7
II. MÉTODOS	8
A. FASE I	9
1) Revisión de variables empleadas en estudios previos.....	9
2) Conformación de la base de datos.....	11
3) Preprocesamiento de datos	12
4) Descripción de modelos propuestos.....	15

5) Abreviación de variables para cada modelo	17
B. FASE II	18
1) División de conjunto de entrenamiento y prueba.....	18
2) Estandarización de variables	18
3) Descripción del modelo LASSO	20
4) Entrenamiento del modelo	23
C. FASE III	25
1) Evaluación de modelos	25
2) Selección del modelo óptimo	27
3) Implementación del modelo óptimo para predicción de f^*c	27
CAPÍTULO III.- RESULTADOS Y DISCUSIÓN	29
I. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS.....	29
A. FASE I	29
1) Revisión de variables empleadas en estudios previos.....	29
2) Conformación de la base de datos.....	30
3) Preprocesamiento de datos	31
4) Modelos propuestos	35
B. FASE II	36
1) División de conjunto de entrenamiento y prueba.....	36
2) Entrenamiento del modelo	37
C. FASE III	44
1) Evaluación de modelos	44
2) Selección del modelo óptimo	47
3) Implementación del modelo óptimo para predicción de f^*c	48
II. VERIFICACIÓN DE HIPÓTESIS	50
A. HIPÓTESIS	50
B. VERIFICACIÓN DE LA HIPÓTESIS.....	50

III. CONCLUSIONES.....	52
IV. RECOMENDACIONES.....	53
REFERENCIAS BIBLIOGRÁFICAS	54

ÍNDICE DE FIGURAS

Fig. 1. Equipo de cómputo utilizado	7
Fig. 2. Metodología aplicada para el modelo LASSO.....	8
Fig. 3. Proceso de estandarización de variables mediante StandardScaler	19
Fig. 4. Representación geométrica de la regularización LASSO	21
Fig. 5. Curva de regularización para la selección del valor óptimo de lambda.....	22
Fig. 6. Esquema de validación cruzada K-fold (K=3) para LASSO	24
Fig. 7. Proceso de aplicación del modelo óptimo.....	28
Fig. 8. Mapa de correlación entre variables predictoras.....	32
Fig. 9. Coeficientes estandarizados del modelo LASSO-1	38
Fig. 10. Coeficientes estandarizados del modelo LASSO-2	39
Fig. 11. Coeficientes estandarizados del modelo LASSO-3.....	41
Fig. 12. Coeficientes estandarizados del modelo LASSO-4	42
Fig. 13. Coeficientes estandarizados del modelo LASSO-5	44
Fig. 14. Diagramas de dispersión de los conjuntos de prueba de los cinco modelos	45
Fig. 15. Gráficos Q-Q de los residuales del conjunto de prueba de los cinco modelos	45
Fig. 16. Comparación de métricas de cada modelo LASSO	47

ÍNDICE DE TABLAS

TABLA I ARTÍCULOS CIENTÍFICOS SELECCIONADOS.....	9
TABLA II RESUMEN DE VARIABLES APLICADAS EN ESTUDIOS AFINES.....	10
TABLA III VARIABLES EMPLEADAS A NIVEL NACIONAL	10
TABLA IV REPOSITARIOS SELECCIONADOS DE UNIVERSIDADES ECUATORIANAS	12
TABLA V ESCALA PARA EL COEFICIENTE DE CORRELACIÓN	14
TABLA VI PLANTEAMIENTO DE MODELOS PARA ENTRENAMIENTO.....	15
TABLA VII VARIABLES PARA EL MODELO LASSO-4	17
TABLA VIII VARIABLES PARA EL MODELO LASSO-5	17
TABLA IX PORCENTAJES DE PARTICIÓN DE DATOS EN ESTUDIOS PREVIOS..	18
TABLA X MÉTRICAS DE EVALUACIÓN EMPLEADAS EN ESTUDIOS PREVIOS	25
TABLA XI RANGOS DE CLASIFICACIÓN DE LAS MÉTRICAS DE EVALUACIÓN	27
TABLA XII LISTA DE VARIABLES PRELIMINARES PARA EL MODELO.....	29
TABLA XIII ESTADÍSTICOS DESCRIPTIVOS DE LAS VARIABLES DE LA BASE DE DATOS INICIAL	31
TABLA XIV MUESTRAS DISPONIBLES EN LA BASE DE DATOS.....	32
TABLA XV PARES CON ALTA CORRELACIÓN	33
TABLA XVI VARIABLES PREDICTORAS DEFINITIVAS.....	33
TABLA XVII CORRELACIÓN DE VARIABLES PREDICTORAS CON LA VARIABLE OBJETIVO.....	34
TABLA XVIII VARIABLES PARA CADA MODELO LASSO PROPUESTO	35
TABLA XIX PARTICIÓN DEL CONJUNTO DE DATOS.....	37
TABLA XX PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-1	37

TABLA XXI PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-2	39
TABLA XXII PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-3	40
TABLA XXIII PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-4	42
TABLA XXIV PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-5	43
TABLA XXV MÉTRICAS DE DESEMPEÑO DE LOS MODELOS ENTRENADOS ..	44
TABLA XXVI CLASIFICACIÓN DEL RENDIMIENTO DE LOS MODELOS ENTRENADOS	47
TABLA XXVII MEDIA Y DESVIACIÓN ESTÁNDAR DE LAS VARIABLES DEL MODELO LASSO-3	48
TABLA XXVIII RESULTADOS DE LA IMPLEMENTACIÓN DEL MODELO	49
TABLA XXIX CAPACIDAD PREDICTIVA DEL MODELO LASSO-3	50

ÍNDICE DE ANEXOS

Anexo 1: Código de exploración inicial y análisis de correlación entre predictores	61
Anexo 2: Código de correlación de predictores con la variable objetivo f_c	67
Anexo 3: Código para entrenamiento del modelo LASSO	69
Anexo 4: Formato para implementación del modelo óptimo para predicción de f_c	80
Anexo 5: Formato base para la recopilación de información	81
Anexo 6: Información recopilada para la base de datos	82
Anexo 7: Base de datos con 32 variables	83
Anexo 8: Datos para aplicación del modelo	87
Anexo 9: Predicción para $f_c=210 \text{ kg/cm}^2$ muestra 1	88
Anexo 10: Predicción para $f_c=210 \text{ kg/cm}^2$ muestra 2	89
Anexo 11: Predicción para $f_c=210 \text{ kg/cm}^2$ muestra 3	90
Anexo 12: Predicción para $f_c=240 \text{ kg/cm}^2$ muestra 1	91
Anexo 13: Predicción para $f_c=240 \text{ kg/cm}^2$ muestra 2	92
Anexo 14: Predicción para $f_c=240 \text{ kg/cm}^2$ muestra 3	93
Anexo 15: Predicción para $f_c=280 \text{ kg/cm}^2$ muestra 1	94
Anexo 16: Predicción para $f_c=280 \text{ kg/cm}^2$ muestra 2	95
Anexo 17: Predicción para $f_c=280 \text{ kg/cm}^2$ muestra 3	96
Anexo 18: Predicción para $f_c=300 \text{ kg/cm}^2$ muestra 1	97
Anexo 19: Predicción para $f_c=300 \text{ kg/cm}^2$ muestra 2	98
Anexo 20: Predicción para $f_c=300 \text{ kg/cm}^2$ muestra 3	99

SIGLAS, ACRÓNIMOS Y ABREVIATURAS

f'_c	Resistencia a compresión del hormigón
LASSO	Least Absolute Shrinkage and Selection Operator
R^2	Coefficiente de determinación
RMSE	Raíz del Error Cuadrático Medio
MAPE	Error Porcentual Absoluto Medio

RESUMEN EJECUTIVO

El presente trabajo desarrolló un modelo de regresión Least Absolute Shrinkage and Selection Operator (LASSO) para la predicción de la resistencia a compresión del hormigón simple a los 28 días, como alternativa a los métodos experimentales tradicionales que requieren ensayos de laboratorio. Se conformó una base de datos de 282 mezclas de hormigón recopiladas de investigaciones publicadas en repositorios universitarios a nivel nacional compuesta por un conjunto de 25 variables predictoras para la construcción de los modelos.

Se propusieron cinco modelos LASSO con distintos conjuntos de predictores, diferenciándose entre modelos con variables de entrada originales y modelos basados en variables tipo ratio. Los cinco modelos fueron entrenados mediante validación cruzada K-fold con $K=3$ para la selección del parámetro de regularización λ óptimo. El modelo LASSO-3, conformado por 25 variables predictoras con transformación logarítmica aplicada a la edad de curado, obtuvo el mejor desempeño con $R^2=0.720$, $RMSE=29.530 \text{ kg/cm}^2$ y $MAPE=10.454\%$, evidenciando que las variables originales capturan mejor la información que las variables tipo ratio en un modelo de regresión lineal regularizado.

Durante la evaluación con mezclas nuevas, el modelo presentó mayor precisión en resistencias medias de 240 kg/cm^2 con $RMSE$ de 11.545 kg/cm^2 y $MAPE$ de 2.944% , y limitaciones por sobreestimación y subestimación en los extremos del rango evaluado (210 y 300 kg/cm^2), comportamiento inherente a los modelos lineales y posible falta de información representativa en dichos rangos. Los resultados obtenidos demuestran la viabilidad del modelo LASSO como herramienta predictiva para el diseño de mezclas de hormigón simple de resistencias normales.

PALABRAS CLAVES: REGRESIÓN LASSO, SELECCIÓN DE VARIABLES, REGULARIZACIÓN L1, RESISTENCIA A LA COMPRESIÓN, HORMIGÓN SIMPLE.

ABSTRACT

This study developed a Least Absolute Shrinkage and Selection Operator (LASSO) regression model to predict the 28-day compressive strength of plain concrete, as an alternative to traditional experimental methods that require laboratory testing. A database of 282 concrete mixes was compiled from research published in national university repositories, consisting of a set of 25 predictor variables for model construction.

Five LASSO models with different sets of predictors were proposed, distinguishing between models with original input variables and models based on ratio-type variables. The five models were trained using K-fold cross-validation with $K=3$ to select the optimal regularization parameter λ . The LASSO-3 model, consisting of 25 predictor variables with a logarithmic transformation applied to the curing age, achieved the best performance with $R^2=0.720$, $RMSE=29.530$ kg/cm², and $MAPE=10.454\%$, demonstrating that the original variables capture the information better than ratio-type variables in a regularized linear regression model.

During the evaluation with new mixtures, the model showed greater accuracy at average strengths of 240 kg/cm² with an $RMSE$ of 11.545 kg/cm² and an $MAPE$ of 2.944%, and limitations due to overestimation and underestimation at the extremes of the evaluated range (210 and 300 kg/cm²), a behavior inherent to linear models and a possible lack of representative data in those ranges. The results obtained demonstrate the viability of the LASSO model as a predictive tool for the design of plain concrete mixtures with normal strengths.

KEYWORDS: LASSO REGRESSION, VARIABLE SELECTION, L1 REGULARIZATION, COMPRESSIVE STRENGTH, PLAIN CONCRETE.

CAPÍTULO I.- MARCO TEÓRICO

I. JUSTIFICACIÓN

El hormigón es uno de los materiales más ampliamente utilizados alrededor del mundo por la industria de la construcción, siendo parte del desarrollo continuo de países y ciudades, a causa de la resistencia, disponibilidad y viabilidad económica que presenta [1].

El hormigón de tipo simple está principalmente compuesto por cemento, agregados finos y gruesos, agua y en otros casos se le agrega aditivos para mejorar sus propiedades [2]. Una de sus principales propiedades mecánicas es la resistencia a esfuerzos de compresión, la cual se puede ver que es influenciada por características de sus componentes tales como, forma de agregados, tamaño, relación agua-cemento, entre otros [1]. La resistencia a la compresión del hormigón, es considerada uno de los puntos más importantes dentro del diseño estructural ya que determina la capacidad que poseerán las estructuras para soportar cargas y garantizar su integridad.

Se considera que los métodos manuales tradicionales utilizados para determinar esta propiedad del hormigón, que conllevan la elaboración de pruebas continuas de laboratorio pueden resultar tediosos y costosos [3]. Además, la resistencia del hormigón incrementa al transcurrir el tiempo, y es determinada a los 28 días después de haber sometido las muestras a su proceso respectivo de curado, pero al ser en sí una propiedad dependiente considerando que el material se encuentra expuesto a factores ambientales externos que influyen de forma directa en su desempeño y obtención de resultados, surge una necesidad de optimizar este proceso [4].

Por otra parte, el sector de la construcción a nivel mundial es considerado una de las principales fuentes de contaminación, siendo que genera significativos niveles de desechos que terminan en botaderos sin ser aprovechados, en función de los recursos que se utilizan previamente de forma masiva [5]. Por ende, la disponibilidad rápida de resultados sobre la resistencia a compresión del hormigón mediante otras alternativas permitiría prevenir desperdicio de material, reducción de costos y optimización de mano de obra, contribuyendo de igual forma a la agilización y cumplimiento de procesos [2].

A causa de esto, en esta industria se han explorado técnicas computacionales para predecir el comportamiento del hormigón y optimizar su control de calidad. En los últimos años, los modelos para manejar conjuntos de datos y realizar predicciones han ganado importancia dentro de la ingeniería civil, los cuales han presentado distintos desempeños según las condiciones de

estudio y observando cuáles son las características más influyentes en la determinación de la resistencia a compresión del hormigón, viéndose así que pueden llegar a presentar predicciones con alta precisión. En la aplicación de estos modelos no es únicamente importante determinar las características más influyentes, sino determinar la relación entre estas, la capacidad del conjunto de datos, variables disponibles, y cómo hay patrones que pueden influir en la precisión de predicción de resultados [6].

Los modelos lineales regularizados suelen utilizarse para evitar el sobreajuste del modelo, de modo que se pueda minimizar el error de varianza sin aumentar el error de sesgo, el modelo Least Absolute Shrinkage And Selection Operator (LASSO) tiende a eliminar las características que determina como menos importantes, a través de una selección automática donde establece ciertos coeficientes como cero, mejorando la interpretabilidad del modelo [7].

Por tales razones, este trabajo experimental permitirá evaluar el grado de precisión con la que se determina la resistencia a compresión del hormigón simple mediante el modelo Least Absolute Shrinkage And Selection Operator (LASSO), sin que esta se vea comprometida reduciendo los tiempos de espera asociados a los ensayos de laboratorio que se basan en determinar resistencias normales a los 28 días, además de reducir los costos relacionados a los recursos y materiales empleados mientras se minimiza el impacto ambiental provocado por los ensayos destructivos tradicionalmente empleados, para promover la aplicación y validación de métodos estadísticos, precisos y eficientes que fomentan prácticas más sostenibles en el campo de la construcción.

II. ANTECEDENTES INVESTIGATIVOS

En una investigación que tuvo como objetivo predecir la resistencia a la compresión del hormigón reforzado con fibras [8], se compararon modelos como Linear Regressor, Support Vector Regression, LASSO, Ridge, ElasticNet, Random Forest y Redes Neuronales Artificiales. Los datos fueron recolectados a través de literatura y se llevaron a cabo 25 ensayos de laboratorio. Los datos disponibles se dividieron en aproximadamente 133 para entrenamiento y 25 para testeo, aquí el modelo contaba con las variables típicas como: cemento, agua, tamaño máximo del agregado, agregado grueso, agregado fino, superplastificante y características de las fibras añadidas. El resultado de LASSO en este caso fue un RMSE= 0.013 MPa, indicando así un ajuste casi perfecto para este caso.

Este estudio determinó que los resultados pueden mejorar si se agregan características o se hace uso de alguna técnica de incremento de datos, considerando que la muestra de datos disponible es un parámetro principal influyente en el desempeño de los modelos de aprendizaje automático [8].

En el estudio [9], realizado con el fin de establecer un modelo eficiente para la predicción del hormigón y establecer una plataforma para evaluar indicadores clave del rendimiento, se hizo la comparación del desempeño de modelos predictivos como Ridge Regression, Elman Neuronal Network, Support Vector Regression, K-Nearest Neighbors y LASSO, cuyos desempeños y precisión se evaluaron de forma detallada, el conjunto para el modelo estaba compuesto por 487 datos y consideraba 9 variables, 8 de entrada, tales como: cemento, ceniza volante, polvo mineral, aditivo, agregado fino, agregado grueso, agua y superplastificante, siendo así la resistencia a compresión la variable de salida. Los datos se sometieron a un preprocesamiento para su debida limpieza y posterior normalización. Se desarrollaron los modelos de forma individual, donde se dividió aleatoriamente el conjunto de entrenamiento y de prueba, asignándole el 80% al primer conjunto y el 20% al de prueba. Las métricas de evaluación utilizadas para determinar su precisión fueron R^2 , MSE, RMSE y MAE y MAPE donde LASSO resultó tener un buen desempeño, presentando una desviación de 5.18 MPa de los valores reales, considerándose un nivel de error aceptable.

A partir del desarrollo de la dicha plataforma, se redujeron considerablemente la cantidad de pruebas y cálculos que normalmente requieren hacer los investigadores e ingenieros, permitiendo así la reducción del trabajo experimental mientras se predice la resistencia a compresión del hormigón de forma innovadora [9].

Bajo el mismo enfoque, la investigación [10], fue elaborada principalmente con el fin de predecir propiedades mecánicas del hormigón mientras se minimizan ensayos costosos y extensos de laboratorio, se entrenaron y evaluaron varios modelos como Linear Ridge, LASSO y SVR, a distintas edades. Los datos se obtuvieron a partir de un repositorio donado, compuesto originalmente por 17 variables, pero algunas fueron eliminadas por condiciones atípicas y falta de datos, resultando así en 1030 diseños de mezclas para los modelos. Las variables finales consideradas fueron: cemento, agua, escoria, ceniza, superplastificante, agregado fino, agregado grueso edad y la resistencia a compresión, es decir nueve variables en total. El conjunto se dividió en 80% para entrenamiento y 20% de prueba. Las métricas evaluadas fueron R^2 , MSE, RMSE y MAE. Una de las principales observaciones de esta investigación fue que una transformación polinomial de las características provocó una caída drástica en la precisión de LASSO a pesar de que fue beneficioso para los otros modelos, y el valor óptimo de lambda (λ) resultó muy cercano a 0 convirtiendo así a LASSO en una regresión lineal básica, y de igual manera el modelo falló prediciendo datos externos.

Se consideró que los datos originales no eran los suficientemente representativos para los diseños de mezcla, además de que el dataset contenía información limitada sobre las composiciones y procedimientos de ensayos, resultando en valores de $R^2=0.40$, $MSE=114.30$ MPa, $RMSE=10.69$ MPa y $MAE=8.46$ MPa [10].

Según una investigación reciente [11], que busca determinar la resistencia a compresión del hormigón, los datos se generaron mediante modelado de datos autodescriptivo, es decir datos sintéticos, conformando así una base de 1000 datos. Las variables fueron: cemento, agua, superplastificante, arena, grava, humo de sílice y fibras en determinados rangos/porcentajes. En este procedimiento se dividió el dataset y se evaluaron modelos como Ridge, LASSO, Random Forest y Support Vector Regression. Aquí LASSO logró una precisión excepcional, con valores resultantes de $R^2=1.00$ y $RMSE=0.01$.

Este estudio combinó la teoría filosófica de la moción sustancial, considerando que los modelos deben seleccionarse según la naturaleza y complejidad de los datos disponibles para que durante el desarrollo del modelo se analicen de forma dinámica los cambios internos que se pueden producir en el hormigón con el paso del tiempo, proporcionando así una comprensión profunda de dichos procesos y contribuyendo a un mejor diseño de materiales [11].

De manera similar, en otro estudio [12], se hizo uso de LASSO para determinar la resistencia a compresión de hormigón de alta resistencia con la misma finalidad de disminuir

tiempos y costos relacionados a la experimentación. Los datos para este estudio fueron recolectados del laboratorio, obteniendo así 167 mezclas de hormigón. Al igual que en las otras investigaciones las principales variables fueron: cemento, humo de sílice, agua, superplastificante, arena, grava, edad y la variable objetivo de resistencia a compresión. Antes del entrenamiento de los modelos, los datos se ajustaron a una misma escala consistente para evitar que alguna característica predominara sobre otras, escalando los valores entre 0 y 1, una vez realizada la normalización de características, los registros se reordenaron a fin de eliminar cualquier sesgo relacionado con el orden y los conjuntos se dividieron en 70% para entrenamiento de los modelos y 30% reservado para el testeo y probar la capacidad de los modelos. En este caso LASSO, obtuvo los siguientes resultados en las métricas evaluadas $R^2=0.622$, $MSE=116.766$ MPa, $MAE=9.321$ MPa.

En esta investigación se concluyó que a pesar de que el modelo no logró capturar interacciones complejas entre las variables, destacó su utilidad para la selección de características, debido a que se deshizo de las variables relativamente innecesarias gracias a su penalización [12].

III. OBJETIVOS

A. OBJETIVO GENERAL

Construir un modelo Least Absolute Shrinkage and Selection Operator (LASSO) para la predicción de la resistencia a compresión del hormigón simple de resistencias normales a los 28 días.

B. OBJETIVOS ESPECÍFICOS

- 1) Conformar una base de datos para la construcción del modelo Least Absolute Shrinkage and Selection Operator (LASSO) para predecir la resistencia a compresión del hormigón simple de resistencias normales a los 28 días.
- 2) Entrenar el modelo Least Absolute Shrinkage and Selection Operator (LASSO) para predecir la resistencia a compresión del hormigón simple de resistencias normales a los 28 días.
- 3) Evaluar el desempeño del modelo Least Absolute Shrinkage and Selection Operator (LASSO) para predecir la resistencia a compresión del hormigón simple de resistencias normales a los 28 días.

CAPÍTULO II.- METODOLOGÍA

La presente investigación consta de tres fases, las cuales se encuentran dentro de un enfoque cuantitativo y tipo experimental, ya que se realizó recolección de datos y un análisis posterior para evaluar el desempeño del modelo aplicado. En la primera fase se realizó la revisión de literatura de las fuentes seleccionadas y descripción de las propuestas de modelo, en la segunda fase se definió el procedimiento para el entrenamiento de los modelos que fueron seleccionados para predecir la resistencia a compresión del hormigón simple a los 28 días y finalmente durante la tercera fase, se establecieron las métricas para realizar la evaluación del desempeño de los modelos entrenados.

I. EQUIPOS Y MATERIALES

A continuación, se detallan los equipos y materiales utilizados en cada fase de la investigación: Para el desarrollo de la primera fase, se usó una laptop (ASUS) con procesador 11th Gen Intel (R) Core (TM) i7-1165G7 y una RAM de 8.00 GB, además de la aplicación de hojas de cálculo Microsoft Excel para la recopilación y organización de información.



Fig. 1. Equipo de cómputo utilizado

Durante la segunda fase, se usó el entorno gratuito Google Colab (Google Colaboratory) para la estructuración de la arquitectura correspondiente al modelo LASSO en código Python (versión 3.12.13) para el entrenamiento del mismo y pronosticar la variable seleccionada.

En la última fase se evaluó el desempeño del modelo aplicando las siguientes métricas, raíz del error cuadrático medio (RMSE), coeficiente de determinación (R^2) y error porcentual absoluto medio (MAPE). Para identificar el error que genera el modelo en la predicción de la resistencia a compresión del hormigón a los 28 días. Y por último se realizó la operacionalización del modelo.

II. MÉTODOS

Las tres fases presentadas a continuación, están relacionadas directamente con el cumplimiento de los objetivos general y específicos para desarrollo de la presente investigación de tipo experimental.

En proyectos de modelado predictivo, comúnmente se considera el uso de pipelines, es decir flujos de trabajo estructurados para organizar el proceso de construcción, entrenamiento y evaluación, a fin de facilitar el desarrollo del modelo seleccionado [13].

Por ende, a continuación, en la Fig. 2, se presenta de forma gráfica el flujo de trabajo general que se llevó a cabo en esta investigación:

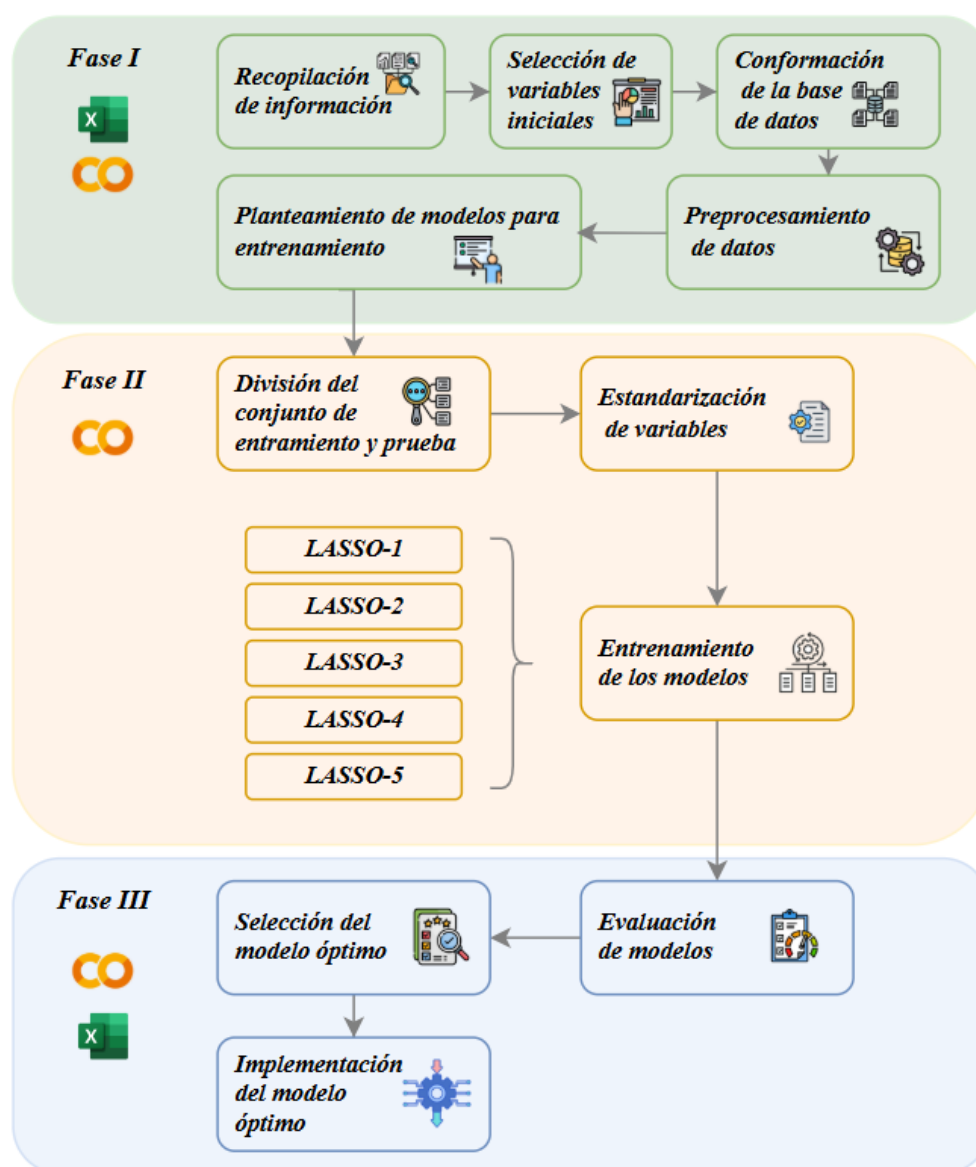


Fig. 2. Metodología aplicada para el modelo LASSO

A. FASE I

1) Revisión de variables empleadas en estudios previos

a) Estudios seleccionados

Los estudios presentados en la TABLA I abordan la predicción de la resistencia a compresión del hormigón mediante distintos modelos, incluyendo LASSO, por lo que fueron seleccionados con el fin de analizar sus enfoques metodológicos e información relevante reportada en cada caso.

TABLA I
ARTÍCULOS CIENTÍFICOS SELECCIONADOS

Año	Título	Autores	Referencia
2022	Experimental validation of compressive strength prediction using machine learning algorithm	Arrun Sivasunramanian, Arathy Krishna S., Devi H Nair, Kripa Varma, Rakhi Radhakrishnan, Dhanya Sathyan	[8]
2023	Development of compressive strength prediction platform for concrete materials based on machine learning techniques	Kenxin Liu, Lingyan Zhang, Weiguang Wang, Guozhi Zhang, Liuliu Xu, Dingqian Fan, Rui Yu	[9]
2025	Prediction of the compressive strength of concrete by machine learning regression models	Hana Schreiberová	[10]
2025	Predicting concrete compressive strength using machine learning and the Theory of Substantial Motion	Hematibahar Mohammad, Makhmud Kharun, Haron Cesar Almeida Tavares, Carlos Humberto Martins	[11]
2025	Machine learning approaches for forecasting compressive strength of high-strength concrete	Mohammed Shaaban, Mohamed Amin, S. Selim, Islam M. Riad	[12]

b) Variables empleadas en los estudios seleccionados

Para la construcción de este modelo, durante la revisión de literatura se identificaron las variables comúnmente empleadas en investigaciones con propósitos similares. En los estudios analizados que implementan este modelo para la predicción de la resistencia a compresión del hormigón [8-11] se evidencia el uso de conjuntos de variables comparables, manteniéndose dentro de un rango limitado que no supera las diez variables incluyendo tanto variables de entrada como de salida.

De igual forma, se identificaron en dichas investigaciones ciertas mezclas de hormigones no convencionales o reforzados con fibras lo que implicó la incidencia de variables adicionales a las típicas en los modelos desarrollados, tales como volumen de fibras, longitud de fibras, diámetro de fibras, porcentajes aplicados y otros componentes. No obstante, estas no se incorporaron dentro de la recopilación ya que son características no propias del hormigón simple, pero en su lugar se conservaron las restantes tradicionales para realizar la comparabilidad entre los estudios seleccionados. En la TABLA II se muestran las variables recopiladas:

TABLA II
RESUMEN DE VARIABLES APLICADAS EN ESTUDIOS AFINES

Variables recopiladas	Autores
Resistencia a compresión del hormigón	[8-12]
Tamaño máximo del agregado	[8]
Edad de ensayo	[10], [12]
Cantidad de agua	[8-12]
Cantidad de cemento	[8-12]
Cantidad de agregado fino	[8-12]
Cantidad de agregado grueso	[8-12]

Por otra parte, en el estudio [14] se presentan 29 variables seleccionadas, incluyendo la variable objetivo, a partir de una extensa revisión bibliográfica, las cuales fueron consideradas como las propiedades más influyentes en la caracterización del hormigón dentro del contexto nacional ecuatoriano según la investigación del autor, estas se presentan en la TABLA III.

TABLA III
VARIABLES EMPLEADAS A NIVEL NACIONAL

Variables de estudio	Unidad de medida
Asentamiento	cm
Densidad del cemento	kg/m ³
Módulo de finura del agregado fino	adimensional
Tamaño máximo del agregado fino	cm
Tamaño nominal máximo del agregado fino	cm
Densidad aparente suelta del agregado fino	kg/m ³
Densidad aparente compactada del agregado fino	kg/m ³
Porcentaje de humedad del agregado fino	%
Porcentaje de absorción del agregado fino	%

Tamaño máximo del agregado grueso	"
Tamaño nominal máximo del agregado grueso	"
Densidad aparente suelta del agregado grueso	kg/m ³
Densidad aparente compactada del agregado grueso	kg/m ³
Porcentaje de humedad del agregado grueso	%
Porcentaje de absorción del agregado grueso	%
Porcentaje óptimo de la arena	%
Porcentaje óptimo de la grava	%
Densidad óptima de la mezcla	kg/m ³
Densidad máxima de la mezcla	kg/m ³
Cantidad de agua	kg
Cantidad de cemento	kg
Cantidad de grava	kg
Cantidad de arena	kg
Cantidad de agua corregida	kg
Cantidad de cemento corregida	kg
Cantidad de grava corregida	kg
Cantidad de arena corregida	kg
Edad del hormigón	Días
Resistencia a la compresión del hormigón	kg/cm ²

A partir del análisis de las propiedades del hormigón empleadas en estos estudios se procedió a conformar un listado con las variables seleccionadas para el entrenamiento del modelo objetivo en esta investigación, asignando además una abreviatura con el fin de facilitar su identificación inicial.

2) Conformación de la base de datos

a) Búsqueda y recopilación de información

Según investigaciones previas [8], [11], [12], el procedimiento de recopilación de datos empleado varía, pero generalmente se presenta que la conformación de la base de datos, puede realizarse a partir de: recolección de datos de ensayos de laboratorio, recopilación de información en literatura previa e incluso generación de datos mediante modelado autodescriptivo. En este caso, se procedió con la revisión de literatura en documentos publicados en repositorios de universidades ecuatorianas que ofertan la carrera de Ingeniería Civil para extraer los datos requeridos.

De igual forma se incluyó la base de datos utilizada en la investigación [14], la cual también fue formada a partir del método de revisión bibliográfica, a fin de ampliar dicho registro de información con nuevos datos.

A continuación, la TABLA IV presenta los repositorios de las universidades seleccionadas, de los cuales se obtuvieron las propiedades del hormigón derivadas de ensayos de laboratorio realizados para la determinación de la resistencia a compresión del hormigón.

TABLA IV
REPOSITORIOS SELECCIONADOS DE UNIVERSIDADES ECUATORIANAS

Repositorio	URL
Universidad Católica de Cuenca	https://dspace.ucacue.edu.ec/
Universidad Católica Santiago de Guayaquil	http://repositorio.ucsg.edu.ec/
Escuela Superior Politécnica del Litoral	https://www.dspace.espol.edu.ec/
Universidad del Azuay	https://dspace.uazuay.edu.ec/
Universidad Técnica de Ambato	https://repositorio.uta.edu.ec/

b) Criterios de selección de información

La Norma Ecuatoriana de la Construcción - Estructuras de Hormigón Armado (NEC-SE-HM) [15], establece entre sus requisitos de propiedades mecánicas de hormigón que los elementos de hormigón normal deben presentar una resistencia mínima $f'_c=21$ MPa y un valor máximo de $f'_c=35$ MPa en elementos de hormigón liviano. Por ende, para la recolección de datos se definieron edades de 7, 14 y 28, considerando valores de resistencia a compresión del hormigón dentro del rango mencionado, expresados en kg/cm^2 , unidad de medida comúnmente utilizada en reportes de ensayos de laboratorio.

3) Preprocesamiento de datos

Después de la conformación de la base de datos inicial, se realizó el preprocesamiento de datos, este incluye varias etapas que tratan los datos recolectados antes de su entrenamiento en el modelo y en este caso se estructuró de la siguiente manera:

a) Limpieza de datos y exploración inicial

Previo a la aplicación de cualquier tipo de proceso de análisis de datos, usualmente se lleva a cabo un proceso de preparación de datos, que implica limpiar, eliminar valores atípicos o faltantes y realizar la respectiva transformación en caso de ser necesario ya que la presencia de

diferencias notables entre los valores de los datos por unidades de medida distintas tiende a generar un sesgo negativo en el rendimiento del modelo [16] .

Primero, se llevó a cabo una revisión general de la base de datos previamente conformada con los datos nuevos, donde se procuró dejar como celdas vacías los datos no encontrados durante la investigación de la base de datos, la cuál es una práctica típica para prever problemas al momento de modelar los datos [17].

De igual forma se realizó una detección manual de valores atípicos, también denominados outliers que son aquellos valores que están lejos de los otros en un conjunto de datos [18]. Esto se realizó mediante la revisión de valores máximos y mínimos de cada variable del conjunto de datos. Dichos valores fueron evaluados en función de su coherencia dentro del conjunto para ser posteriormente corregidos o eliminados [19].

La carga del dataset se realizó mediante la función `pd.read_excel()` de la librería pandas [20], almacenando los datos en un `DataFrame`. El código implementado detecta automáticamente el formato del archivo de entrada, admitiendo archivos con extensión `.xlsx`, `.xls` y `.csv`.

Posteriormente se llevó a cabo una exploración inicial del dataset mediante las funciones `head()` e `info()` de pandas, las cuales permitieron verificar la correcta carga de los datos e identificar los tipos de variables. A continuación, las filas que presentaban valores faltantes fueron verificadas mediante la función `isnull().sum()` y posteriormente eliminadas, mediante el método `dropna()` ya que al no representar un alto porcentaje respecto al total de la base de datos es aceptable.

Finalmente, sobre el dataset ya depurado, se calcularon los estadísticos descriptivos de cada columna respectivamente mediante la función `describe()`, obteniendo para cada variable los valores de media, desviación estándar, mínimo y máximo.

Adicionalmente, se verificó la distribución de muestras disponibles en la base de datos según la edad de ensayo, identificando el número de datos a los 7, 14 y 28 días. Todo esto previo a la selección de las características más útiles dentro de las propiedades del hormigón para no incluir datos no representativos en el modelo y eliminar cualquier tipo de información redundante entre las variables finales que se incluyeron en el modelo [19].

b) Análisis de correlación entre variables predictoras

La correlación se entiende como una medida donde las variables presentan interdependencia entre sí. Dependiendo el método, la relación posible existente entre las variables puede ser expresada mediante una relación directa o negativa, tomando valores de -1 a +1, donde -1 representa una relación lineal negativa perfecta, 0 muestra ausencia de relación entre variables y +1 una relación positiva perfecta [21].

Una de las correlaciones más utilizadas para medir la relación lineal entre dos variables en investigaciones es el Coeficiente de Correlación de Pearson [22], cuya fórmula se expresa como:

$$r_{xy} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} = \frac{\sum d_x d_y}{\sqrt{\sum d_x^2 \sum d_y^2}} \quad (1)$$

Donde,

$\sum d_x d_y$ Suma de los productos de las desviaciones

$\bar{X}$ y $\bar{Y}$ Medias muestrales de X y Y

$\sum d_x^2 \sum d_y^2$ Suma de cuadrados de X y Y

Por lo tanto, para esta investigación se realizaron pruebas de correlación aplicando el coeficiente R de Pearson, mediante la función `.corr()` de la librería `pandas`, únicamente considerando las variables preliminares independientes del modelo, es decir se excluyó a la variable dependiente `f'c` y se representó el resultado gráficamente mediante un mapa de calor el cual fue generado mediante la función `sns.heatmap()` de la librería `seaborn` [23].

La investigación [24] , presenta una tabla resumen respecto a las escalas que mencionan diversos autores para la interpretación del coeficiente de correlación, donde se muestra una gran variabilidad de opiniones, por lo que para este estudio se decidió considerar una de dichas clasificaciones la cual se muestra en la TABLA V.

TABLA V
ESCALA PARA EL COEFICIENTE DE CORRELACIÓN

Valor absoluto (Correlación: positiva/negativa)												
Referencia	1.00	0.90	0.89	0.70	0.69	0.50	0.49	0.30	0.29	0.10	0.09	0.00
[25]	Asociación muy alta		Asociación alta		Asociación moderada		Asociación mediana		Asociación pequeña		Asociación nula	

Según [26], en caso de existir una alta correlación entre las variables se denomina como multicolinealidad, la cual es un problema ya que las variables del conjunto independiente no deberían presentar dependencia directa hacia otra dentro del mismo conjunto, generando posibles complicaciones al ajustar el modelo. Por esto se procedió a eliminar las variables que presentaron este problema de multicolinealidad, según los valores de coeficientes obtenidos tomando un coeficiente ≥ 0.9 como referencia para que los pares que superen este valor sean identificados como altamente correlacionados y criterio ingenieril. Este procedimiento fue implementado mediante el código presentado en el Anexo 1, que incluye la exploración inicial y el análisis de pares multicolineales.

c) Correlación de predictores con la variable objetivo $f'c$

Después de la eliminación de variables con multicolinealidad, se calculó el coeficiente de correlación de Pearson entre cada variable predictora y la resistencia a compresión mediante el método `corrwith` de la librería `pandas` con el fin de evaluar la relación lineal individual de cada predictor con la variable objetivo, mediante el código mostrado en el Anexo 2. Los resultados se ordenaron de mayor a menor correlación absoluta para identificar los predictores con mayor asociación lineal con $f'c$. Adicionalmente, se agregó una sección para detectar y excluir automáticamente las variables con varianza cero, cuya correlación resulta indefinida, ya que no aportan información al modelo.

4) Descripción de modelos propuestos

A fin de identificar el mejor conjunto de variables que proporcione una mejor capacidad predictiva para la resistencia a compresión del hormigón ($f'c$), se estructuraron cinco propuestas de conjuntos para entrenar, las cuales se presentan en la TABLA VI.

TABLA VI
PLANTEAMIENTO DE MODELOS PARA ENTRENAMIENTO

Modelo	Variable dependiente	Descripción de las variables independientes
LASSO-1	$f'c$	Todas las variables seleccionadas posterior al análisis de correlación entre variables predictoras
LASSO-2	$f'c$	Variables con mayor correlación con $f'c$ identificadas en la base de datos empleada en el modelo LASSO-1
LASSO-3	$f'c$	Todas las variables seleccionadas aplicando una transformación logarítmica natural a la variable “edad”

LASSO-4	$f'c$	Variables derivadas de relaciones entre componentes del hormigón, conservando la transformación logarítmica natural a la variable “edad”
LASSO-5	$f'c$	Variables derivadas de relaciones respecto al cemento, conservando la transformación logarítmica natural a la variable “edad”

Para el modelo LASSO-1, se conservaron todas las variables conservadas posteriormente al análisis de correlación entre predictores. En el caso del modelo LASSO-2, a partir de la observación del análisis de correlación de las variables predictoras con la variable objetivo $f'c$, se seleccionaron aquellas de mayor influencia que presentaron valores de correlación mayores a 0.1.

Posteriormente, se aplicaron técnicas de transformación de variables. Este proceso se denomina linealización de variables, el cual consiste en transformar la relación no lineal entre dos variables para que el modelo pueda capturar una relación lineal [27].

Uno de estos métodos de linealización, es la transformación logarítmica natural (base e), la cual permite que los datos cumplan de mejor manera con las condiciones de la aplicación de la regresión lineal [28]. Entonces para el modelo LASSO-3 previo a la carga del dataset, se aplicó una transformación logarítmica natural a la variable edad de curado directamente sobre el archivo de datos mediante la función $\text{LN}()$ de Excel, sustituyendo los valores originales de edad en días por su equivalente $\ln(\text{edad})$, con el fin de linealizar la relación no lineal existente entre dicha variable y la resistencia a compresión del hormigón, dado que la relación mencionada sigue un comportamiento logarítmico característico del proceso de hidratación y curado del cemento.

Otra técnica es la transformación a ratios, que consiste en convertir las cantidades absolutas de los materiales que componen el hormigón en proporciones relativas. En lugar de usar las variables por separado, tales como las cantidades en kg de agua, cemento, arena y grava, se crean nuevas variables, como por ejemplo la relación agua-cemento, el cual es un factor crítico comúnmente considerado ya que demuestra directamente la hidratación del hormigón, y según los valores se identifica la resistencia y durabilidad del hormigón [27]. Por tanto, se aplicó esta técnica a fin de reducir las variables originales y dejar relaciones proporcionales significativas para los modelos LASSO-4 y LASSO-5, conservando la transformación logarítmica de la variable edad.

Las relaciones fueron seleccionadas dado que, para un mismo conjunto de materiales, lo que varía entre dosificaciones son principalmente las cantidades de los agregados, por lo que se procedió a expresarlas de formas distintas para evaluar la capacidad que tiene el modelo para capturar de forma más directa la diferencia entre las mezclas.

En el caso del modelo LASSO-4, las variables derivadas de ratios son las indicadas en la TABLA VII. Estas variables conservan unidades adimensionales y las cantidades de agua, arena, cemento y grava incluidas en la base de datos.

TABLA VII
VARIABLES PARA EL MODELO LASSO-4

Variables	Abreviación
Logaritmo natural de la edad	$\ln(\text{Edad})$
Relación agua-cemento	a/c
Relación arena-grava	ar/g
Relación arena/(arena+grava)	$ar/(ar+g)$
Relación pasta/(arena+grava)	$p/(ar+g)$

Para el modelo LASSO-5 (ver TABLA VIII) se siguió el mismo criterio y cabe señalar que tanto este como el modelo LASSO-4 comparten las variables $\ln(\text{Edad})$ y a/c , diferenciándose únicamente en las otras relaciones consideradas.

TABLA VIII
VARIABLES PARA EL MODELO LASSO-5

Variables	Abreviación
Logaritmo natural de la edad	$\ln(\text{Edad})$
Relación agua-cemento	a/c
Relación arena-cemento	ar/c
Relación grava-cemento	g/c

5) *Abreviación de variables para cada modelo*

A partir de la selección definitiva de variables, estas se definieron en dos conjuntos. La variable objetivo o dependiente que corresponde a la resistencia a compresión del hormigón expresada en kg/cm^2 (f'_c) y las variables predictoras que fueron seleccionadas para la conformación de cada modelo.

Y con el propósito de facilitar la representación de las nuevas variables incorporadas en las propuestas de modelos que resultaban de relaciones entre componentes del hormigón, se conservaron abreviaciones específicas para evitar expresiones extensas durante el reporte de resultados.

B. FASE II

1) División de conjunto de entrenamiento y prueba

Según los artículos seleccionados previamente, existen ciertas variaciones entre los porcentajes asignados a los conjuntos de entrenamiento y prueba de sus modelos, los cuales se detallan a continuación en la TABLA IX:

TABLA IX
PORCENTAJES DE PARTICIÓN DE DATOS EN ESTUDIOS PREVIOS

Fuente	Número de muestras	Entrenamiento (%)	Prueba (%)
[8]	158	85%	15%
[9]	487	80%	20%
[10]	1030	80%	20%
[12]	167	70%	30%

Bajo este contexto, para este trabajo se decidió tomar una división de porcentaje de entrenamiento y prueba del 80% - 20% respectivamente mediante la función `train_test_split` de la librería `scikit-learn` [29]. De igual forma, se estableció el parámetro `random_state=42` para asegurar que la partición de datos se mantuviera igual en cada ejecución del código.

2) Estandarización de variables

Otra etapa fundamental, consiste en la estandarización de los datos, a una escala común a fin de minimizar el sesgo mediante una distribución específica. Para esta investigación, se aplicó la técnica de estandarización de datos mediante el transformador `StandardScaler` de la librería `scikit-learn`. Esta herramienta permite que los datos escalados tengan una media cero y varianza unitaria. Una de las ventajas de este método es que, a diferencia de otros métodos de escalado, no restringe los datos en un rango definido, por lo que ante la posible presencia de valores atípicos se ve menos afectado [19].

$$z = \frac{(x_i - \mu)}{s} \quad (2)$$

Donde,

Z	Valor estandarizado de la variable predictora i
x_i	Variable predictora i
μ	Media de la variable predictora i
s	Desviación estándar de variable predictora i

También es importante considerar la posible filtración de datos también denominada data leakage, este es un proceso en el cual la información del conjunto de prueba influye en la etapa de preprocesamiento dando como resultado métricas que no reflejan el rendimiento real del modelo [29] .

Para evitar esto, el ajuste del escalador se realizó sobre el conjunto de entrenamiento mediante `fit_transform`, donde se calcularon los parámetros de μ y s , a partir del número de muestras pertenecientes al 80% y se transformaron los valores simultáneamente en una escala estandarizada. Posteriormente, los resultados de los parámetros obtenidos del conjunto de prueba fueron transferidos y aplicados al conjunto de prueba utilizando únicamente `transform`, para evitar recalcular nuevos valores de μ y s , ya que los nuevos datos deben ser procesados con la escala aprendida previamente y no recalibrados nuevamente, como se muestra en la Fig. 3.




Fig. 3. Proceso de estandarización de variables mediante StandardScaler

3) Descripción del modelo LASSO

El modelo de regresión lineal LASSO, también denominado Operador de Selección y Contracción Mínima, es un método de estadística y aprendizaje automático supervisado, cuya función principal es la regularización y selección de variables. En el ámbito del aprendizaje automático resulta especialmente útil para casos donde existe un gran número de variables respecto a la muestra disponible [30].

La regresión lineal como modelo estadístico asume una relación lineal entre una o más variables independientes y la variable dependiente, y dicha expresión se representa mediante una ecuación simple [31]:

$$y = \beta_0 x_0 + \beta_1 x_1 + \dots + \beta_n x_n + \varepsilon \quad (3)$$

Donde,

y	Valor predicho
β_0	Intercepto del modelo
β_n	Coefficientes de cada variable i estimados por el modelo
x_0	Valor igual a 1
x_n	Variables predictoras estandarizadas
ε	Término de error

a) Regularización

La regresión lineal es un método que permite modelar la relación entre una variable dependiente y una o varias variables independientes mediante el método de mínimos cuadrados ordinarios (OLS) donde se trata de minimizar la diferencia entre valores observados y predichos.

No obstante, pueden surgir problemas de sobreajuste o inestabilidad al trabajar con múltiples variables por lo que surgen las técnicas de regularización, las cuales ayudan a restringir los coeficientes de regresión del modelo para controlar su complejidad y evitar valores

extremos. Entre estas, una de las técnicas de regularización más comunes es LASSO, también llamada regularización L1 [32].

La base de este modelo consiste en agregar un término de penalización a la función objetivo original. En este caso, el error del modelo se mide mediante la suma residual de cuadrados (RSS), que representa la suma de las diferencias al cuadrado entre los valores observados y predichos [33]. Expresándose la función del modelo de forma simplificada de la siguiente manera:

$$\text{Función objetivo} = (RSS) + \lambda * \sum |\beta_j| \quad (4)$$

Donde,

RSS	Suma residual de cuadrados
λ	Parámetro de regularización que controla la penalización del modelo
β_j	Vector de coeficientes de regresión asociados a cada variable independiente

b) Parámetro de penalización λ (lambda)

Uno de los puntos más importantes de ajuste del este modelo, es la selección del parámetro de penalización λ (lambda). Su valor controla tanto el número de variables que serán seleccionadas como el grado en que los coeficientes del modelo serán reducidos a cero controlando el sesgo. Si el valor de λ es demasiado grande, provocará que todos o casi todos los coeficientes resulten nulos, mientras que un valor cercano a cero dejará muchas variables o ruido en el modelo, convirtiéndolo en un modelo ordinario [34].

Dicho comportamiento puede representarse de la siguiente manera:




Fig. 4. Representación geométrica de la regularización LASSO

Visualmente las elipses se pueden interpretar como las curvas de nivel de la función de costo de mínimos cuadrados ordinarios, y la región de restricción del modelo se expresa gráficamente con forma de diamante debido a su regularización L1, la cual representa el espacio de coeficientes permitidos evitando que estos crezcan libremente. Las esquinas del diamante se ubican sobre los ejes de coordenadas, y la ubicación de los coeficientes en dichas zonas provocan que estos tomen valores igual a cero, realizando así una selección automática de variables según su importancia [35].

Uno de los métodos comúnmente utilizados para hallar el valor de λ , es la técnica de validación cruzada de la cuál existen varias versiones, pero la más ampliamente aplicada para el análisis de datos reales es la validación cruzada K-fold, la cual fue seleccionada para este proyecto [36].

Para la implementación de la validación cruzada K-fold en LASSO, los datos de entrenamiento se dividen de forma aleatoria en K subconjuntos, también llamados pliegues o folds, de tamaño aproximadamente igual, siendo los valores más utilizados K=5 o K=10. En cada ronda, uno de los folds queda apartado como conjunto de validación para medir el error de predicción, mientras que los K-1 folds restantes se utilizan para entrenar el modelo con un valor de λ determinado. Este proceso se repite hasta que cada fold haya actuado como conjunto de validación exactamente una vez. Al finalizar, se obtiene el promedio de los errores de las K rondas, el cual representa el error de validación cruzada $CV(\lambda)$ para ese valor de λ . Este procedimiento se repite para cada λ de la cuadrícula y se selecciona aquel que minimiza dicho error promedio, siendo este el λ óptimo con el que se entrena el modelo final [36].

Dicho comportamiento puede observarse en la Fig. 5, donde se muestra la curva de error de validación cruzada en función de λ , identificándose el valor óptimo en el punto mínimo de la curva.




Fig. 5. Curva de regularización para la selección del valor óptimo de lambda

c) Estimación de coeficientes del modelo

El descenso de coordenadas es un método variante del descenso de gradiente que, en lugar de actualizar todos los parámetros simultáneamente, actualiza los valores de la secuencia (iteraciones) de uno en uno por coordenada [37].

El uso de este método se considera ideal para LASSO, ya que en cada paso del descenso la actualización del coeficiente β_j se realiza calculando primero un coeficiente de mínimos cuadrados simples y aplicando después un operador de contracción suave. Estableciendo así el coeficiente en cero si su valor cae por debajo de un umbral determinado por el parámetro de regularización λ [38].

4) Entrenamiento del modelo

Para la selección del parámetro de regularización λ óptimo, se empleó la clase `LassoCV` de la librería `scikit-learn`, definiendo una cuadrícula de 1000 valores en escala logarítmica en el intervalo $[0.0001, 100]$, generada mediante la función `np.logspace` de la librería `NumPy` [39]. Se optó por definir explícitamente este rango debido al tamaño reducido del conjunto de entrenamiento, para evitar que el rango automático de `LassoCV` propusiera valores de λ excesivamente grandes en un dataset pequeño, derivando en la eliminación de todos los coeficientes del modelo.

La selección de λ se realizó mediante validación cruzada K-fold con $K=3$, valor elegido en función del tamaño del conjunto de entrenamiento a fin de que cada subconjunto de validación contuviera un número suficiente de observaciones, lo que proporcionó una estimación del error más estable que la obtenida con $K=5$ o $K=10$ (Fig. 6). En cada fold, el error de predicción se cuantificó mediante el error cuadrático medio (MSE), métrica utilizada internamente por `LassoCV` para comparar el desempeño de cada valor de λ evaluado en la cuadrícula. El λ óptimo corresponde al valor que minimiza el MSE promedio entre los folds.

El parámetro `random_state=42` garantizó la reproducibilidad de la división en folds. El número máximo de iteraciones del algoritmo de descenso por coordenadas se estableció en 10000 (`max_iter=10000`) para asegurar la convergencia del modelo en todas las combinaciones de λ y fold evaluadas. Todo esto se realizó mediante la línea de código `lasso_cv = LassoCV(alphas=alphas, cv=3, random_state=42, max_iter=10000, n_jobs=-1)`.




Fig. 6. Esquema de validación cruzada K-fold (K=3) para LASSO

Una vez identificado el λ óptimo por la validación cruzada, se entrenó el modelo final usando la clase Lasso de Scikit-learn con ese λ específico sobre el conjunto de entrenamiento completo. Se mantuvo el mismo límite de `max_iter=10000` establecido durante la validación cruzada para garantizar la convergencia del algoritmo de descenso por coordenadas. Lo cual se realizó mediante las líneas de código `modelo_lasso = Lasso(alpha=lambda_optimo, max_iter=10000)` y `modelo_lasso.fit(X_train_sc, y_train)`.

Mediante la función `fit()` se ejecutó el descenso por coordenadas: actualizando cada coeficiente β uno a la vez, ciclando sobre todas las variables repetidamente hasta que los cambios entre iteraciones fueron menores que la tolerancia por defecto (`tol=0.0001`) o se alcanzó el límite de 10000 iteraciones.

Después, para la extracción de los coeficientes del modelo se utilizó la línea de código `coeficientes=pd.Series(modelo_lasso.coef_, index=X.columns).sort_values(key='abs', ascending=False)`, donde se generó una serie con los coeficientes β ordenados por magnitud absoluta de mayor a menor. Los coeficientes iguales a cero son las variables que LASSO eliminó automáticamente mediante la penalización L1 y la función `modelo_lasso.intercept_`, devolvió el término independiente β_0 , que es el valor base de la predicción cuando las variables se encuentran en escala estandarizada.

Finalmente, a partir de los coeficientes obtenidos, se construyó la ecuación de cada modelo entrenado con LASSO, mostrando así los coeficientes de las variables seleccionadas por el modelo. Cada ecuación expresa la resistencia a compresión f'_c en función de las variables estandarizadas, con su respectivo intercepto y término de error ε . El tiempo de ejecución del código de entrenamiento, incluyendo la validación cruzada para la selección de λ óptimo y el entrenamiento del modelo final, fue de aproximadamente 13 segundos en el entorno de Google Colaboratory. El código completo de entrenamiento del modelo utilizado se presenta en el Anexo 3.

C. FASE III

1) Evaluación de modelos

a) Métricas comúnmente utilizadas

La TABLA X muestra las métricas utilizadas en los estudios seleccionados de la TABLA I que han utilizado el modelo seleccionado para predecir de la propiedad objetivo del hormigón (f'_c):

TABLA X
MÉTRICAS DE EVALUACIÓN EMPLEADAS EN ESTUDIOS PREVIOS

Métricas	Fuente
R^2 , MSE	[8]
R^2 , MAE, RMSE, MSE, MAPE	[9]
R^2 , MSE, RMSE, MAE	[10]
R^2 , RMSE	[11]
R^2 , MSE, MAE	[12]

A partir de esto, la evaluación del modelo se realizó mediante los indicadores matemáticos seleccionados R^2 , MAPE y RMSE, para determinar la efectividad del modelo en la predicción de la resistencia a compresión del hormigón e interpretarla de forma sencilla. En este caso se descartó la métrica MSE por ser matemáticamente equivalente al cuadrado de RMSE, sin aportar información adicional y MAE se descartó por ser óptima para errores con una distribución distinta [40].

b) Coeficiente de determinación (R^2)

R^2 , también identificado como coeficiente de determinación, se interpreta como la proporción de la varianza en la variable dependiente que es predecible a partir de las variables independientes. El peor valor posible resultante en esta métrica son valores negativos que tiendan a infinito, y entre más se acerque a uno positivo, es considerado mejor valor [41].

$$R^2 = 1 - \frac{\sum_{i=1}^m (X_i - Y_i)^2}{\sum_{i=1}^m (\bar{Y} - Y_i)^2} \quad (5)$$

Donde,

X_i	Valor predicho
Y_i	Valor real
$\bar{Y}$	Promedio de valores reales

c) Error Cuadrático Medio (RMSE)

RMSE también es una de las métricas más utilizadas, realiza una comparación entre los valores reales y los predichos mediante el cálculo de una raíz cuadrada del error promedio residual, obteniendo así el error en las unidades de la variable analizada. El valor ideal para alcanzar en esta métrica es cero, ya que representa un ajuste perfecto entre la predicción y la realidad [42].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{a}_i - a_i)^2}{n}} \quad (6)$$

Donde,

$\hat{a}_i$	Valor predicho
a_i	Valor real
n	Número de observaciones

d) Error Porcentual Absoluto Medio (MAPE)

MAPE, de igual forma es una de las medidas de precisión comúnmente utilizadas, ya que presenta características importantes como facilidad de interpretación y claridad, por lo que también fue usada para analizar los resultados del modelo. En esta métrica el mejor valor tiende a 0 y el peor posible a infinito [41].

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|\hat{y}_t - y_t|}{y_t} * 100 \quad (7)$$

Donde,

$\hat{y}_t$	Valor predicho
y_t	Valor real
n	Número de observaciones

2) Selección del modelo óptimo

A continuación, en la TABLA XI, se presenta una clasificación propuesta de las métricas para modelos de regresión lineal en la investigación [43] para R^2 y RMSE, la cual se complementó con información de clasificación sobre MAPE de la investigación [44] cuyos rangos de rendimiento siguen siendo ampliamente considerados en investigaciones actuales.

TABLA XI
RANGOS DE CLASIFICACIÓN DE LAS MÉTRICAS DE EVALUACIÓN

Clasificación de rendimiento de métricas			
Clasificación	R^2	RMSE	MAPE
Excelente	>0.90	<10	<10%
Muy bueno	0.80-0.90	10-20	10%-20%
Bueno	0.70-0.80	20-30	20%-50%
Satisfactorio	0.60-0.70	30-40	-
Insatisfactorio	<0.60	>40	>50%

Estos rangos se tomaron en cuenta para calificar el rendimiento final de los modelos entrenados y seleccionar el modelo óptimo para realizar la aplicación del mismo en la predicción de la resistencia a compresión del hormigón a los 28 días.

3) Implementación del modelo óptimo para predicción de f'_c

Posterior a la selección del modelo óptimo, para su aplicación se generó una herramienta en una hoja de cálculo de Excel para la predicción de la resistencia a compresión del hormigón a partir del ingreso de nuevos datos de mezcla no vistos por el modelo, cuyo formato se presenta en el Anexo 4, conformado a partir de los coeficientes e intercepto obtenidos en el modelo de mejor rendimiento, este proceso se llevó a cabo de la forma indicada en la Fig. 7.




Fig. 7. Proceso de aplicación del modelo óptimo

CAPÍTULO III.- RESULTADOS Y DISCUSIÓN

I. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS

En este capítulo se presentan los resultados obtenidos a partir de la metodología establecida en el capítulo anterior. Durante la primera fase las variables definitivas fueron seleccionadas y se realizó la conformación de la base de datos, en la segunda fase se establecieron los parámetros y valores para el modelo LASSO y durante la última fase se realizó la evaluación del rendimiento de los modelos entrenados para su posterior selección e implementación para realizar predicciones de la resistencia a compresión del hormigón a los 28 días con datos nuevos de mezclas.

A. FASE I

1) Revisión de variables empleadas en estudios previos

A partir de realizar una comparación entre las variables pertenecientes a la literatura de [8], [9], [10], [11], [12], y la base de datos perteneciente al estudio [14], se determinó la presencia de siete variables de los estudios internacional en el modelo de la base de datos proporcionada, las cuales son: resistencia a compresión del hormigón, edad de ensayo, cantidad de agua, cantidad de cemento, cantidad de agregado fino, cantidad de agregado grueso y tamaño máximo del agregado.

a) Recopilación de variables

Inicialmente se conservó de forma preliminar las variables presentes en el estudio que empleó modelos de regresión lineal múltiples [14], a las cuales se les incorporaron tres variables predictoras adicionales. La relación agua-cemento fue incluida por constituir uno de los factores principales que influyen en la resistencia a compresión, mientras que la densidad aparente del agregado grueso y la densidad aparente del agregado fino son un parámetro de caracterización de los áridos determinado mediante las normas NTE INEN 856 [45] y NTE INEN 857 [46], otorgándoles de forma inicial las abreviaciones mostradas a continuación en la TABLA XII:

TABLA XII
LISTA DE VARIABLES PRELIMINARES PARA EL MODELO

Nº	Variables	Unidades	Abreviación
1	Resistencia a compresión del hormigón	kg/cm ²	fc
2	Asentamiento del hormigón	cm	Asent_hormigon
3	Densidad del cemento	gr/cm ³	Dens_cemento

4	Módulo de finura (Agregado fino)	adimensional	MF_af
5	Tamaño máximo (Agregado fino)	cm	TM_af
6	Tamaño Nominal Máximo (Agregado fino)	cm	TNM_af
7	Densidad Aparente Suelta (Agregado fino)	kg/m ³	DAS_af
8	Densidad Aparente Compacta (Agregado fino)	kg/m ³	DAC_af
9	Porcentaje de humedad (Agregado fino)	%	Porc_hum_af
10	Porcentaje de absorción (Agregado fino)	%	Porc_abs_af
11	Densidad Aparente (Agregado fino)	kg/m ³	DA_af
12	Tamaño máximo (Agregado grueso)	"	TM_ag
13	Tamaño Nominal Máximo (Agregado grueso)	"	TNM_ag
14	Densidad Aparente Suelta (Agregado grueso)	kg/m ³	DAS_ag
15	Densidad Aparente Compacta (Agregado grueso)	kg/m ³	DAC_ag
16	Porcentaje de humedad (Agregado grueso)	%	Porc_hum_ag
17	Porcentaje de absorción (Agregado grueso)	%	Porc_abs_ag
18	Densidad Aparente (Agregado grueso)	kg/m ³	DA_ag
19	Porcentaje óptimo de arena	%	Porc_opt_af
20	Porcentaje óptimo de grava	%	Porc_opt_ag
21	Densidad óptima de la mezcla	kg/m ³	DOmezcla
22	Densidad máxima de la mezcla	kg/m ³	DMmezcla
23	Cantidad de agua	kg	Agua
24	Cantidad de cemento	kg	Cemento
25	Cantidad de arena	kg	Arena
26	Cantidad de grava	kg	Grava
27	Cantidad de agua corregida	kg	Agua_corr
28	Cantidad de cemento corregida	kg	Cemento_corr
29	Cantidad de arena corregida	kg	Arena_corr
30	Cantidad de grava corregida	kg	Grava_corr
31	Relación agua-cemento	adimensional	a/c
32	Edad del hormigón	días	Edad

2) Conformación de la base de datos

Una vez seleccionadas las 32 variables preliminares, se procedió a establecer un formato (Anexo 5) en una hoja de cálculo para organizar las variables de las cuales se recolectó la información que cumplieran con los criterios de selección previamente establecidos sobre las propiedades del hormigón para conformar la base de datos.

En el Anexo 6, se presenta de forma resumida la nueva información conformada por treinta trabajos experimentales pertenecientes a los repositorios listados en la TABLA IV para adicionar a la base proporcionada.

3) *Preprocesamiento de datos*

a) *Limpieza de datos y exploración inicial*

Inicialmente se verificó la carga del archivo con la información correspondiente de las variables preliminares seleccionadas y el número de muestras total compuesta por los registros presentados en la base de datos de la investigación [14] y los datos recopilados, mostrados en el Anexo 7. En esta etapa se identificaron 6 valores faltantes correspondientes a las filas de densidad aparente del agregado fino y densidad aparente del agregado grueso, dando, así por eliminación un resultante de 276 filas para la determinación de los valores estadísticos presentados en la TABLA XIII.

TABLA XIII
ESTADÍSTICOS DESCRIPTIVOS DE LAS VARIABLES DE LA BASE DE DATOS INICIAL

Variable	Unidades	Count	Mean	Std	Min	Max
fc	kg/cm ²	276	204.847	49.777	100.700	374.080
Asent_hormigon	cm	276	7.106	2.782	2.350	22.000
Dens_cemento	gr/cm ³	276	2.875	0.134	2.400	3.161
MF_af	adimensional	276	2.711	0.369	1.750	4.540
TM_af	cm	276	0.503	0.296	0.187	1.270
TNM_af	cm	276	0.192	0.148	0.093	0.990
DAS_af	kg/m ³	276	1518.985	120.175	1155.200	1950.000
DAC_af	kg/m ³	276	1645.961	120.336	1352.270	2080.000
Porc_hum_af	%	276	2.640	2.172	0.000	12.420
Porc_abs_af	%	276	2.288	1.557	0.000	8.560
DA_af	kg/m ³	276	2581.780	118.074	2309.789	2915.367
TM_ag	"	276	1.486	0.554	0.748	3.810
TNM_ag	"	276	1.016	0.384	0.500	2.540
DAS_ag	kg/m ³	276	1415.687	128.307	1230.000	1740.000
DAC_ag	kg/m ³	276	1533.078	134.287	1320.000	1880.000
Porc_hum_ag	%	276	1.666	2.370	0.000	15.360
Porc_abs_ag	%	276	2.382	1.573	0.400	10.090
DA_ag	kg/m ³	276	2635.431	118.381	2273.178	2900.000
Porc_opt_af	%	276	0.413	0.062	0.260	0.640
Porc_opt_ag	%	276	0.587	0.062	0.360	0.740
DO_mezcla	kg/m ³	276	1941.696	202.755	1391.000	2639.480
DM_mezcla	kg/m ³	276	1960.658	191.172	1692.000	2639.480
Agua	kg	276	200.117	25.604	123.340	287.000
Cemento	kg	276	366.690	68.067	235.850	685.040
Arena	kg	276	731.422	128.750	432.438	1350.220
Grava	kg	276	1015.832	121.062	667.000	1345.000

Agua_corr	kg	276	200.021	25.970	123.340	287.000
Cemento_corr	kg	276	366.690	68.067	235.850	685.040
Arena_corr	kg	276	732.796	129.108	432.438	1350.220
Grava_corr	kg	276	1016.419	120.914	667.000	1345.000
a/c	adimensional	276	0.553	0.072	0.260	0.758
Edad	días	276	16.917	9.123	7.000	28.000

A continuación, la TABLA XIV resume la cantidad de filas de muestras disponibles clasificadas por edad.

TABLA XIV
MUESTRAS DISPONIBLES EN LA BASE DE DATOS

Edad (días)	Nº de muestras	%
7	95	34.40%
14	76	27.50%
28	105	38.00%
Total	276	100.00%

b) Análisis de correlación entre variables predictoras

Con el total de 31 predictores se realizó el análisis de correlación, cuyos resultados se presentan en la Fig. 8, mostrando únicamente las variables que presentaron al menos un par de correlación superior al umbral >0.90 establecido.




Fig. 8. Mapa de correlación entre variables predictoras

De forma resumida, la TABLA XV presenta los pares de predictores determinados con problemas de multicolinealidad.

TABLA XV
PARES CON ALTA CORRELACIÓN

N° de par	Variable 1	Variable 2	r
1	Porc_opt_af	Porc_opt_ag	-0.9978
2	DO_mezcla	DM_mezcla	0.9622
3	Agua	Agua_corr	0.9891
4	Cemento	Cemento_corr	1.0000
5	Arena	Arena_corr	0.9986
6	Grava	Grava_corr	0.9997

De los pares de variables de las cantidades de agua, cemento, arena y grava, se conservó la cantidad corregida por humedad debido a lo que dichos valores representan los reales utilizados en la mezcla, descartando las cantidades originales que resultan ser redundantes dentro del modelo. En el caso de la densidad óptima y densidad máxima de la mezcla, se optó por conservar la densidad óptima ya que es el valor de referencia de diseño de uno de los métodos principalmente estipulado a nivel nacional y por último se optó por conservar el porcentaje óptimo de arena, siendo que de igual forma es un parámetro de diseño principal [47].

Resultando así una base de datos definitiva compuesta por 25 variables independientes, como se muestra en la TABLA XVI.

TABLA XVI
VARIABLES PREDICTORAS DEFINITIVAS

N°	Variables	Unidades	Abreviación
1	Asentamiento del hormigón	cm	Asent_hormigon
2	Densidad del cemento	gr/cm ³	Dens_cemento
3	Módulo de finura (Agregado fino)	adimensional	MF_af
4	Tamaño máximo (Agregado fino)	cm	TM_af
5	Tamaño Nominal Máximo (Agregado fino)	cm	TNM_af
6	Densidad Aparente Suelta (Agregado fino)	kg/m ³	DAS_af
7	Densidad Aparente Compacta (Agregado fino)	kg/m ³	DAC_af
8	Porcentaje de humedad (Agregado fino)	%	Porc_hum_af
9	Porcentaje de absorción (Agregado fino)	%	Porc_abs_af
10	Densidad Aparente (Agregado fino)	kg/m ³	DA_af
11	Tamaño máximo (Agregado grueso)	"	TM_ag

12	Tamaño Nominal Máximo (Agregado grueso)	"	TNM_ag
13	Densidad Aparente Suelta (Agregado grueso)	kg/m ³	DAS_ag
14	Densidad Aparente Compacta (Agregado grueso)	kg/m ³	DAC_ag
15	Porcentaje de humedad (Agregado grueso)	%	Porc_hum_ag
16	Porcentaje de absorción (Agregado grueso)	%	Porc_abs_ag
17	Densidad Aparente (Agregado grueso)	kg/m ³	DA_ag
18	Porcentaje óptimo de arena	%	Porc_opt_af
19	Densidad óptima de la mezcla	kg/m ³	DOmezcla
20	Cantidad de agua corregida	kg	Agua_corr
21	Cantidad de cemento corregida	kg	Cemento_corr
22	Cantidad de arena corregida	kg	Arena_corr
23	Cantidad de grava corregida	kg	Grava_corr
24	Relación agua-cemento	adimensional	a/c
25	Edad del hormigón	días	Edad

c) Correlación de predictores con la variable objetivo $f'c$

El análisis de correlación realizado entre las variables independientes resultantes de la eliminación previa, respecto a la variable objetivo dio como resultado los valores presentados en la TABLA XVII a continuación:

TABLA XVII
CORRELACIÓN DE VARIABLES PREDICTORAS CON LA VARIABLE OBJETIVO

Predictor	Correlación con $f'c$
Edad	+0.693
Porc_abs_ag	+0.227
DAC_af	+0.151
Dens_cemento	-0.135
DA_ag	-0.129
a/c	-0.127
DA_af	-0.110
TM_af	-0.109
Porc_opt_af	-0.076
DOmezcla	-0.072
Porc_hum_ag	-0.069
TM_ag	-0.064
Cemento_corr	+0.061
Porc_abs_af	-0.061

MF_af	-0.058
DAC_ag	+0.049
Asent_hormigon	+0.041
Agua_corr	-0.041
Porc_hum_af	-0.033
TNM_ag	-0.032
DAS_ag	+0.024
DAS_af	0.021
Arena_corr	-0.009
Grava_corr	-0.008
TNM_af	-0.007

Aquí fue posible identificar como la variable con mayor correlación respecto a $f'c$, a la edad, mientras que a partir de la variable $Porc_opt_af$ la relación con la variable objetivo cae considerablemente con valores menores a 0.1, umbral a partir del cual las variables que presentan estos valores no se consideran como relevantes.

4) Modelos propuestos

La TABLA XVIII resume la composición de los modelos estructurados (LASSO-1 a LASSO-5), todos con la resistencia a compresión ($f'c$) como variable dependiente, diferenciándose en el conjunto de variables predictoras incluidas. LASSO-1 y LASSO-3 incorporan el mayor número de variables originales, incluyendo propiedades tanto del agregado fino como del agregado grueso, mientras que LASSO-2 considera un subconjunto intermedio y los modelos LASSO-4 y LASSO-5 trabajan con un conjunto más reducido de predictores.

TABLA XVIII
VARIABLES PARA CADA MODELO LASSO PROPUESTO

Variables	LASSO-1	LASSO-2	LASSO-3	LASSO-4	LASSO-5
Variable dependiente					
fc	✓	✓	✓	✓	✓
Variables originales					
Asent_hormigon	✓		✓		
Dens_cemento	✓	✓	✓		
MF_af	✓		✓		
TM_af	✓	✓	✓		
TNM_af	✓		✓		

DAS_af	✓		✓		
DAC_af	✓	✓	✓		
Porc_hum_af	✓		✓		
Porc_abs_af	✓		✓		
DA_af	✓	✓	✓		
TM_ag	✓		✓		
TNM_ag	✓		✓		
DAS_ag	✓		✓		
DAC_ag	✓		✓		
Porc_hum_ag	✓		✓		
Porc_abs_ag	✓	✓	✓		
DA_ag	✓	✓	✓		
Porc_opt_af	✓		✓		
DO_mezcla	✓		✓		
Agua_corr	✓		✓		
Cemento_corr	✓		✓		
Arena_corr	✓		✓		
Grava_corr	✓		✓		
a/c	✓	✓	✓	✓	✓
Edad	✓	✓			
Transformación logarítmica					
Logaritmo natural de la edad			✓	✓	✓
Variables derivadas (ratios)					
Relación arena-cemento					✓
Relación grava-cemento					✓
Relación arena-grava				✓	
Relación arena/(arena+grava)				✓	
Relación pasta/(arena+grava)				✓	
Número de variables independientes	25	8	25	5	4

B. FASE II

1) División de conjunto de entrenamiento y prueba

La TABLA XIX muestra la partición de datos aplicada a cada grupo de modelos, los modelos LASSO-1, LASSO-2 y LASSO-3, utilizaron variables con datos faltantes por lo que se eliminaron filas y para el modelo LASSO-4 y LASSO-5, al operar sobre variables derivadas sin valores faltantes se utilizó el número completo observaciones. En ambos casos la división fue de 80% entrenamiento y 20% prueba, y la estandarización se aplicó únicamente al conjunto de entrenamiento para evitar fuga de información.

TABLA XIX
PARTICIÓN DEL CONJUNTO DE DATOS

Modelos	Conjunto	Número de muestras	%
LASSO-1, LASSO-2, LASSO-3	Entrenamiento	220 muestras	(80%)
	Prueba	56 muestras	(20%)
	Total	276 muestras	(100%)
LASSO-4, LASSO-5	Entrenamiento	225 muestras	(80%)
	Prueba	57 muestras	(20%)
	Total	282 muestras	(100%)

2) Entrenamiento del modelo

a) Modelo LASSO-1

La TABLA XX resume los parámetros de selección de λ para el primer modelo. El valor obtenido mediante LassoCV fue de 0.07126, valor relativamente bajo dentro del rango de búsqueda, lo que indica que el conjunto de datos contenía señal suficiente para sostener un modelo con poca penalización, y por ende la regularización L1 eliminó solo 1 de los 25 predictores disponibles.

TABLA XX
PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-1

Selección de λ LASSO-1	
Rango de búsqueda	(0.0001, 100.0)-1000 valores
λ óptimo (LassoCV)	0.071261
Validación cruzada	K-fold, K=3
Predictores seleccionados	24 de 25
Predictores eliminados	1

Como se observa en la Fig. 9, las variables de mayor peso en el modelo son la relación agua-cemento ($\beta = -38.716$) y la edad de curado ($\beta = 33.780$), seguidas del agua corregida y el

cemento corregido. El signo negativo de a/c , representa que a un mayor valor de esta relación se reduce la resistencia, lo cual es consistente en la práctica.

La variable Por_opt_af fue eliminada en este modelo, a causa de que probablemente esa información fue capturada por la cantidad de arena en la mezcla, volviendo así a la variable redundante ya que el modelo ya posee esa información de otra forma y decidió llevar su coeficiente a cero.




Fig. 9. Coeficientes estandarizados del modelo LASSO-1

La ecuación final del modelo LASSO-1 es la siguiente:

$$\begin{aligned}
 fc = & 202.843 - 38.716(a/c) + 33.780(Edad) \\
 & + 25.837(Agua_corr) - 24.751(Cemento_corr) \\
 & + 19.183(Porc_abs_ag) + 13.013(Arena_corr) \\
 & - 9.851(Porc_abs_af) - 7.777(TM_ag) \\
 & - 7.084(DA_ag) + 6.594(DAC_ag) \\
 & - 4.778(DAS_af) - 4.332(Dens_cemento) \\
 & - 4.176(TM_af) - 4.158(DO_mezcla) \\
 & + 4.100(TNM_ag) + 2.711(DAC_af) \\
 & - 2.504(Porc_hum_ag) - 2.446(MF_af) \\
 & + 2.153(Grava_corr) - 1.893(TNM_af) \\
 & + 1.867(Asent_hormigon) + 1.535(DA_af) \\
 & - 1.183(Porc_hum_af) + 0.324(DAS_ag) + \varepsilon
 \end{aligned} \tag{8}$$

Donde las variables se definen según la TABLA XVI.

b) Modelo LASSO-2

La TABLA XXI resume los parámetros de selección de λ para el modelo LASSO-2. El valor óptimo obtenido fue de 0.45463, considerablemente mayor al del LASSO-1, lo que refleja una mayor penalización necesaria para generalizar con un conjunto reducido de 8 predictores. A pesar de este valor de λ más alto, la regularización L1 no eliminó ninguna variable, reteniendo los 8 predictores disponibles en el modelo. Debido al número reducido de variables estas tienen aún más peso y eliminar una sería perder información importante dentro de este conjunto limitado, entonces el modelo optó por contraer los coeficientes aún más en vez de eliminarlos.

TABLA XXI
PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-2

Selección de λ LASSO-2	
Rango de búsqueda	(0.0001, 100.0)-1000 valores
λ óptimo (LassoCV)	0.45463
Validación cruzada	K-fold, K=3
Predictores seleccionados	8 de 8
Predictores eliminados	0

Como se observa en la Fig. 10, la edad de curado ($\beta = 32.086$) es el predictor de mayor peso positivo, seguida de la absorción del agregado grueso ($\beta = 11.272$). Las variables con mayor influencia negativa son la densidad aparente del agregado grueso y la relación agua-cemento. La variable de menor peso es Da_af, pero no se elimina porque aporta incluso con un valor pequeño de información que no posee ninguna otra variable.




Fig. 10. Coeficientes estandarizados del modelo LASSO-2

La ecuación final del modelo LASSO-2 es la siguiente:

$$\begin{aligned}
 fc = & 202.843 + 32.086(Edad) + 11.272(Porc_abs_ag) \\
 & - 6.518(DA_ag) - 5.941(a/c) - 5.371(TM_af) \\
 & - 2.386(Dens_cemento) + 2.043(DAC_ag) \\
 & + 0.504(DA_af) + \varepsilon
 \end{aligned} \tag{9}$$

Donde las variables se definen según la TABLA XVI.

c) Modelo LASSO-3

La TABLA XXII resume los parámetros de selección de λ para el modelo LASSO-3. El valor óptimo obtenido fue de 0.04392, el más bajo de los tres primeros modelos, lo que indica que con el conjunto completo de 25 predictores el modelo requiere menor penalización para generalizar, reteniendo todos los predictores disponibles.

Esto demuestra que la transformación logarítmica de la variable edad, introdujo un mejor ajuste en su relación con la variable objetivo que benefició a todo el modelo y por ende resultó en una menor contracción.

TABLA XXII
PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-3

Selección de λ LASSO-3	
Rango de búsqueda	(0.0001, 100.0)-1000 valores
λ óptimo (LassoCV)	0.043918
Validación cruzada	K-fold, K=3
Predictores seleccionados	25 de 25
Predictores eliminados	0

Como se observa en la Fig. 11, la relación agua-cemento ($\beta = -38.932$) y el logaritmo natural de la edad ($\beta = 34.221$) continúan siendo de los predictores más dominantes, resultando similar a LASSO-1 y le siguen las cantidades de agua y cemento corregidos.

De igual forma se pudo observar que las variables de menor peso son DAS_ag ($\beta = 0.351$) y Porc_opt_af ($\beta = -0.657$), las cuales se aproximaron a cero, pero no fueron eliminadas por el bajo valor de lambda que fue encontrado.




Fig. 11. Coeficientes estandarizados del modelo LASSO-3

La ecuación final del modelo LASSO-3 es la siguiente:

$$\begin{aligned}
 fc = & 202.843 - 38.932(a/c) + 34.221(\ln(Edad)) \\
 & + 25.165(Agua_corr) - 24.829(Cemento_corr) \\
 & + 19.032(Porc_abs_ag) + 12.951(Arena_corr) \\
 & - 9.558(Porc_abs_af) + 7.057(DAC_ag) \\
 & - 6.852(DA_ag) - 6.526(TM_ag) \\
 & - 5.423(DAS_af) - 4.769(DO_mezcla) \\
 & - 4.211(TM_af) - 3.657(Dens_cemento) \\
 & + 3.499(DAC_af) + 3.373(TNM_ag) \\
 & - 2.804(MF_af) + 2.443(Asent_hormigon) \\
 & - 2.416(Porc_hum_ag) - 2.034(TNM_af) \\
 & + 1.309(DA_af) + 1.204(Grava_corr) \\
 & - 1.060(Porc_hum_af) - 0.657(Porc_opt_af) \\
 & + 0.351(DAS_ag) + \varepsilon
 \end{aligned} \tag{10}$$

Donde las variables se definen según la TABLA XVI.

d) Modelo LASSO-4

La TABLA XXIII resume los parámetros de selección de λ para el modelo LASSO-4. En este caso, el valor óptimo fue de 0.09140, mayor al de LASSO-1 y LASSO-3, lo que refleja que

con variables derivadas tipo ratio el modelo requiere mayor penalización para generalizar. Aun así, con este valor, ninguno de los 5 predictores disponibles fue eliminado.

Al parecer la introducción de ratios provocó pérdida de información, pero igual cada relación contenía señal suficiente de forma individual para no ser eliminada.

TABLA XXIII
PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-4

Selección de λ LASSO-4	
Rango de búsqueda	(0.0001, 100.0)-1000 valores
λ óptimo (LassoCV)	0.091403
Validación cruzada	K-fold, K=3
Predictores seleccionados	5 de 5
Predictores eliminados	0

Como se observa en la Fig. 12, en este caso las variables predictoras dominantes son ar/g y ln(Edad), ambos con influencia positiva sobre f^*c . Destaca que ar/(ar+g) presenta un coeficiente negativo de magnitud similar, lo cual era previsto dado que ambas variables están matemáticamente relacionadas ya que resultan de los mismos componentes.

En este caso la relación a/c mantiene su signo negativo, pero pasó a ser menos influyente, disminuyendo su importancia a comparación de los otros modelos, por las nuevas relaciones empleadas, lo que indica que la relación arena-grava puede llegar a ser más influyente.




Fig. 12. Coeficientes estandarizados del modelo LASSO-4

La ecuación final del modelo LASSO-4 es la siguiente:

$$fc = 203.804 + 38.924(ar/g) - 37.064(ar/(ar + g)) + 34.698(\ln(Edad)) - 6.725(a/c) - 1.724(p/(ar + g)) + \varepsilon \quad (11)$$

Donde las variables se definen según la TABLA VII.

e) *Modelo LASSO-5*

La TABLA XXIV resume los parámetros de selección de λ para el modelo LASSO-5. El valor óptimo fue de 0.07126, igual al del LASSO-1 por coincidencia, es decir la validación cruzada lo determinó como el punto óptimo ya que de por sí la información es limitada, y ninguno de los 4 predictores fue eliminado.

Al ser el modelo con menor número de variables, sugiere que de forma obligada todas las razones utilizadas aportaron información relevante para la predicción de $f'c$ y por ello fueron conservadas.

TABLA XXIV
PARÁMETROS DE SELECCIÓN DE LAMBDA DEL MODELO LASSO-5

Selección de λ LASSO-5	
Rango de búsqueda	(0.0001, 100.0)-1000 valores
λ óptimo (LassoCV)	0.071261
Validación cruzada	K-fold, K=3
Predictores seleccionados	4 de 4
Predictores eliminados	0

Como se observa en la Fig. 13, la variable $\ln(Edad)$ continúa siendo uno de los predictores dominantes, seguido de la relación agua-cemento. La relación arena-cemento ($\beta = 3.698$) aportó positivamente indicando que tiene una interacción similar que el agua con el cemento pero a menor intensidad, mientras que la relación grava-cemento presentó un peso casi nulo, lo que muestra que su contribución al modelo es casi despreciable y podría haberse eliminado con un λ ligeramente mayor.




Fig. 13. Coeficientes estandarizados del modelo LASSO-5

La ecuación final del modelo LASSO-5 es la siguiente:

$$fc = 203.804 + 33.870(\ln(Edad)) - 7.546(a/c) + 3.698(ar/c) - 0.063(g/c) + \varepsilon \quad (12)$$

Donde las variables se definen según la TABLA VIII.

C. FASE III

1) Evaluación de modelos

A continuación, la TABLA XXV presenta las métricas de desempeño obtenidas para los cinco modelos LASSO entrenados.

TABLA XXV
MÉTRICAS DE DESEMPEÑO DE LOS MODELOS ENTRENADOS

Descripción	Conjunto	Métrica R ²	RMSE (kg/cm ²)	MAPE (%)
LASSO-1	Train	0.690	26.603	9.839
	Test	0.713	29.922	11.193
LASSO-2	Train	0.568	31.397	11.792
	Test	0.613	34.765	12.779
LASSO-3	Train	0.706	25.929	9.744
	Test	0.720	29.530	10.454
LASSO-4	Train	0.540	33.247	12.285
	Test	0.529	34.810	13.154
LASSO-5	Train	0.505	34.499	13.094
	Test	0.458	37.350	13.979

Con el fin de evaluar el ajuste de cada modelo la Fig. 14 presenta los diagramas de dispersión de resistencia predicha versus la resistencia real obtenidos del conjunto de prueba.




Fig. 14. Diagramas de dispersión de los conjuntos de prueba de los cinco modelos

Y la Fig. 15 presenta los Q-Q plots de residuales correspondientes a cada modelo.




Fig. 15. Gráficos Q-Q de los residuales del conjunto de prueba de los cinco modelos

Se observa que los modelos con variables directas, es decir sin relaciones entre variables, como LASSO-1, LASSO-2 y LASSO-3 obtuvieron en general mejores métricas que los otros dos modelos basados en ratios, lo que sugiere que las relaciones lineales entre cantidades absolutas de los materiales y la resistencia son más fáciles de capturar por un modelo de regresión lineal regularizado. En el caso de LASSO-1 y LASSO-3, presentaron resultados de R^2 menores que los obtenidos en la investigación [11] cuya predicción fue prácticamente perfecta, pero se toma en cuenta el hecho de que la información utilizada en dicho trabajo fueron datos sintéticos y no mezclas reales por ende no es comparable, mientras que el trabajo [12], que incluía resistencias de valores más altos con un número menor de muestras en la base de datos utilizada presentó un $R^2=0.622$ y por tanto menor al de los dos mejores modelos de esta investigación pero similar al de LASSO-2 y cabe resaltar que la diferencia del número de variables entre ambas investigaciones no es muy significativa.

En cambio, las variables derivadas tipo ratio, si bien tienen sustento físico, y minimizan la cantidad de variables utilizadas, probablemente introducen relaciones de naturaleza no lineal que LASSO no logra modelar con la misma eficiencia. Los modelos LASSO-4 y LASSO-5 presentaron valores cercanos, pero por sobre del resultado de $R^2= 0.400$ reportado en la investigación [10] que trabajó con 1030 datos, lo que indica que a pesar del número de muestras disponibles estas no eran suficientemente representativas al igual que el reducido conjunto de variables utilizadas.

Un comportamiento importante a tomar en cuenta, es el de la diferencia entre los resultados de entrenamiento y prueba, ya que esto permite identificar posibles casos de sobreajuste o subajuste. En los modelos LASSO-1 y LASSO-3 el R^2 de prueba supera ligeramente al de entrenamiento, lo que indica una generalización adecuada sin sobreajuste, al igual que LASSO-2 y LASSO-4. En cambio, LASSO-5 es el único modelo donde el R^2 de prueba (0.458) cae por debajo del de entrenamiento (0.505), pero de igual forma no se identificaron casos significativos de sobreajuste y subajuste en los cinco modelos entrenados.

Los diagramas de dispersión de la Fig. 14 reflejan visualmente estas diferencias mencionadas. En el caso de LASSO-1 y LASSO-3 la nube de puntos se distribuye de forma compacta alrededor de la línea de predicción perfecta, mientras que en LASSO-4 y LASSO-5 la nube es notoriamente más dispersa, y se puede observar visualmente que tienen mayor presencia de puntos alejados de la diagonal en ambos extremos del rango.

Por otra parte, los Q-Q plots de la Fig. 15 muestran que en todos los modelos la distribución de residuales sigue la línea teórica normal en la región central, pero presentan desviaciones en los extremos, las cuales son más marcadas en LASSO-4 y LASSO-5, indicando que estos son los modelos que acumulan errores de mayor magnitud en dichos rangos de resistencia.

2) Selección del modelo óptimo

A continuación, la Fig. 16 , presenta de forma visual cada una de las métricas obtenidas en el conjunto de prueba de los cinco modelos entrenados.




Fig. 16. Comparación de métricas de cada modelo LASSO

Y según los rangos de clasificación establecidos en la TABLA XI, el rendimiento de cada modelo se clasifica en la TABLA XXVI de la siguiente manera:

TABLA XXVI
CLASIFICACIÓN DEL RENDIMIENTO DE LOS MODELOS ENTRENADOS

Modelo	R^2	RMSE	MAPE
LASSO-1	Bueno	Bueno	Muy bueno
LASSO-2	Satisfactorio	Satisfactorio	Muy bueno
LASSO-3	Bueno	Bueno	Muy bueno
LASSO-4	Insatisfactorio	Satisfactorio	Muy bueno
LASSO-5	Insatisfactorio	Satisfactorio	Muy bueno

Según la clasificación obtenida, los modelos LASSO-1 y LASSO-3 presentan una clasificación resultante similar en las tres métricas aplicadas, seguidos por el modelo LASSO-2 y finalmente los modelos LASSO-4 y LASSO-5, donde R^2 y RMSE resultan insatisfactorios, a pesar de esto, todos los modelos según los rangos de clasificación de MAPE, se reportan como

muy buenos al estar dentro de un rango de 10% al 20%, lo que indica que en términos porcentuales el error de predicción se mantiene dentro de un nivel aceptable incluso en los modelos de menor desempeño.

Con base en esto, se seleccionó el modelo LASSO-3 como el modelo óptimo al obtener la mejor clasificación en las métricas ($R^2 = 0.720$, $RMSE = 29.530 \text{ kg/cm}^2$, $MAPE = 10.454\%$), manteniéndose por un margen de variación pequeño sobre el modelo LASSO-1 ($R^2 = 0.713$, $RMSE = 29.922 \text{ kg/cm}^2$, $MAPE = 11.193\%$), ya que si bien ambos modelos comparten el mismo conjunto de variables, LASSO-3 incorpora la transformación logarítmica de la edad, lo que le permite capturar de forma más adecuada la relación no lineal existente con la resistencia a compresión del hormigón para mayor consistencia en sus predicciones.

3) Implementación del modelo óptimo para predicción de f'_c

Se seleccionaron 12 fuentes de información de las cuales se extrajo la información correspondiente a resistencias alrededor de 210 kg/cm^2 , 240 kg/cm^2 , 280 kg/cm^2 y 300 kg/cm^2 esto se presenta resumido en el Anexo 8.

De igual forma, en la TABLA XXVII se presentan los valores de media y desviación estándar del modelo LASSO-3 por cada variable, estos se agregaron al formato elaborado en Excel para agilizar el cálculo de f'_c añadiendo los coeficientes de la ecuación (10) resultante del entrenamiento del modelo óptimo seleccionado.

TABLA XXVII
MEDIA Y DESVIACIÓN ESTÁNDAR DE LAS VARIABLES DEL MODELO LASSO-3

Variables	Media (train)	Desviación estándar (train)
Asent_hormigon	7.047	2.923
Dens_cemento	2.879	0.130
MF_af	2.705	0.364
TM_af	0.512	0.296
TNM_af	0.196	0.149
DAS_af	1517.676	124.096
DAC_af	1646.206	120.781
Porc_hum_af	2.694	2.181
Porc_abs_af	2.322	1.571
DA_af	2578.694	120.327
TM_ag	1.478	0.552
TNM_ag	1.007	0.383
DAS_ag	1419.037	126.925
DAC_ag	1535.439	132.295

Porc_hum_ag	1.666	2.407
Porc_abs_ag	2.384	1.633
DA_ag	2632.632	120.982
Porc_opt_af	0.413	0.060
DO_mezcla	1948.160	206.973
Agua_corr	200.306	25.732
Cemento_corr	366.061	67.484
Arena_corr	734.582	131.198
Grava_corr	1008.736	119.555
a/c	0.555	0.073
Edad	2.636	0.578

Una vez sintetizada la información en la hoja de cálculo, se procedió a ingresar los datos para cada dosificación y verificar el error en la predicción de $f'c$ a los 28 días mediante el modelo LASSO-3. La TABLA XXVIII presenta los resultados obtenidos en cada predicción.

TABLA XXVIII
RESULTADOS DE LA IMPLEMENTACIÓN DEL MODELO

Resultados de aplicación del modelo						
Dosificación	Nº de mezcla	$f'c$ real (kg/cm ²)	$f'c$ predicho (kg/cm ²)	Error (kg/cm ²)	Error %	Anexo
210 kg/cm ²	1	208.390	242.664	34.274	16.447	Anexo 9
	2	217.320	235.041	17.721	8.154	Anexo 10
	3	210.410	210.184	0.226	0.107	Anexo 11
				RMSE (kg/cm²)	MAPE %	
				22.277	8.236	
240 kg/cm ²	1	240.041	220.083	19.958	8.314	Anexo 12
	2	251.948	251.861	0.087	0.035	Anexo 13
	3	257.050	255.807	1.243	0.484	Anexo 14
				RMSE (kg/cm²)	MAPE %	
				11.545	2.944	
280 kg/cm ²	1	271.030	263.502	7.528	2.777	Anexo 15
	2	281.000	252.271	28.729	10.224	Anexo 16
	3	283.450	228.699	54.751	19.316	Anexo 17
				RMSE (kg/cm²)	MAPE %	
				35.961	10.772	
300 kg/cm ²	1	303.468	219.544	83.924	27.655	Anexo 18
	2	325.110	272.326	52.784	16.236	Anexo 19
	3	329.920	268.534	61.386	18.606	Anexo 20
				RMSE (kg/cm²)	MAPE %	
				67.324	20.832	

Según los valores obtenidos se pudo observar que, en resistencias bajas, el modelo tiende a sobreestimar los valores, mientras que, si la resistencia aumenta, este tiende a subestimar los valores, presentando así una mejor precisión en rangos medios de resistencia. Estos resultados son consistentes con lo previamente observado en el diagrama de dispersión del conjunto de prueba de este modelo (Ver Fig. 14).

De los cuatro grupos de resistencias evaluadas, las que están alrededor de 240 kg/cm² obtuvieron el menor error RMSE (11.545 kg/cm²) y MAPE (2.944%), manteniendo errores relativamente muy bajos y dentro del rango de error estimado en el modelo seleccionado, seguido de las resistencias alrededor de 210 kg/cm² que presentan sobreestimación en sus valores, cabe observar que dentro de estas mezclas una muestra presentó un error muy bajo a comparación de las otras dos analizadas, lo que denota que probablemente dichos datos son muy representativos dentro de la información con la que fue entrenado el modelo LASSO-3, siendo así un caso individual que se puede presentar con otras muestras, lo que indica que no siempre existirá sobreestimación o subestimación en los extremos.

Por otro lado, las mezclas de 280 kg/cm² y 300 kg/cm² presentaron el mayor error, superando así el RMSE (29.530 kg/cm²) y MAPE (10.454 %) del modelo seleccionado en prueba. Estas diferencias reflejan las limitaciones del modelo, donde posibles factores externos no contemplados en las variables del modelo pueden influir en la precisión de predicciones individuales.

II. VERIFICACIÓN DE HIPÓTESIS

A. HIPÓTESIS

La aplicación del modelo de regresión Least Absolute Shrinkage and Selection Operator (LASSO) permite estimar la resistencia a la compresión del hormigón simple a los 28 días, con una capacidad predictiva de RMSE inferior a 20,195 kg/cm².

B. VERIFICACIÓN DE LA HIPÓTESIS

Se realizó una comparación de valores de error del modelo óptimo seleccionado presentada en la TABLA XXIX para la verificación de la hipótesis.

TABLA XXIX CAPACIDAD PREDICTIVA DEL MODELO LASSO-3

Descripción	R ²	RMSE (kg/cm ²)	MAPE (%)
Modelo LASSO-3	0.720	29.530	10.454

Los resultados rechazan la hipótesis planteada, ya que el modelo LASSO-3 obtuvo un valor RMSE de 29.530 kg/cm², valor que supera el umbral propuesto. A pesar de esto, el modelo demostró una capacidad predictiva aceptable durante su entrenamiento, siendo clasificado como bueno y muy bueno según la clasificación determinada en la TABLA XXVI.

CAPÍTULO IV.- CONCLUSIONES Y RECOMENDACIONES

III. CONCLUSIONES

- 1) Se construyó un modelo LASSO que presentó sobreestimación de resistencias bajas y subestimación de resistencias altas, indicando que su capacidad predictiva depende principalmente de la representatividad de los datos utilizados durante el entrenamiento del modelo. A pesar de la menor precisión en los valores extremos del rango de resistencia de 210 kg/cm^2 a 350 kg/cm^2 , el modelo es capaz de responder adecuadamente cuando la información de las mezclas se encuentra dentro de las características más frecuentes de la base de datos utilizada.
- 2) Se conformó una base de datos integrada inicialmente por 282 mezclas de hormigón simple recopiladas de investigaciones publicadas en repositorios a nivel nacional y la base de datos previa utilizada como referencia, donde luego del proceso de limpieza, los modelos LASSO-1, LASSO-2 y LASSO-3 fueron entrenados con 276 registros y los otros modelos basados en variables derivadas utilizaron 282 registros al no presentar valores faltantes en sus variables. Los modelos LASSO-1, LASSO-2 y LASSO-3 se construyeron a partir de un conjunto de 25 variables predictoras, mientras que los modelos LASSO-4 y LASSO-5 emplearon 5 y 4 variables derivadas tipo ratio, respectivamente, conservando en ambos casos la transformación logarítmica natural aplicada a la variable edad.
- 3) Se entrenaron cinco modelos, obteniéndose en el conjunto de prueba valores de $R^2=0.713$, $\text{RMSE}=29.922 \text{ kg/cm}^2$ y $\text{MAPE}=11.193\%$ para LASSO-1; $R^2=0.613$, $\text{RMSE}=34.765 \text{ kg/cm}^2$ y $\text{MAPE}=12.779\%$ para LASSO-2; $R^2=0.720$, $\text{RMSE}=29.530 \text{ kg/cm}^2$ y $\text{MAPE}=10.454\%$ para LASSO-3; $R^2=0.529$, $\text{RMSE}=34.810 \text{ kg/cm}^2$ y $\text{MAPE}=13.154\%$ para LASSO-4; y $R^2=0.458$, $\text{RMSE}=37.350 \text{ kg/cm}^2$ y $\text{MAPE}=13.979\%$ para LASSO-5. Donde el modelo LASSO-3 obtuvo el mejor rendimiento, evidenciando que el modelo con cantidades absolutas de los materiales y transformación logarítmica en la variable más correlacionada captura de mejor manera la relación no lineal existente, aportando mayor información predictiva que uno basado en ratios, considerando que es un modelo lineal aplicado a datos experimentales reales.

- 4) Se evaluó el desempeño del modelo óptimo seleccionado, LASSO-3, mediante su aplicación a dosificaciones externas para predecir la resistencia a compresión del hormigón a los 28 días. En las mezclas de 210 kg/cm² se obtuvo un RMSE de 22.277 kg/cm² y un MAPE de 8.236%, mientras que en las mezclas de rangos medios como 240 kg/cm² se evidenció la mejor capacidad predictiva, alcanzando un RMSE de 11.545 kg/cm² y un MAPE de 2.944%. Por su parte, las mezclas de 280 kg/cm² y 300 kg/cm² presentaron mayores errores, con RMSE de 35.961 kg/cm² y 67.324 kg/cm² y MAPE de 10.772% y 20.832% respectivamente, evidenciando una menor precisión en los rangos superiores de resistencia para este modelo.

IV. RECOMENDACIONES

- 1) Explorar modelos de aprendizaje automático no lineal para captar mejor el comportamiento entre las variables influyentes en la predicción de la resistencia a compresión del hormigón y reducir la tendencia a sobreestimación y subestimación en valores de resistencias extremos lo cual es inherente a un modelo lineal como LASSO.
- 2) Ampliar de forma progresiva la base de datos para investigaciones futuras a fin de actualizar la información incorporando mezclas adicionales en rangos extremos, para reducir las limitaciones del modelo derivadas de la falta de representatividad de información en rangos bajos y altos.
- 3) Evaluar en futuras investigaciones otras estrategias de transformación y combinación de variables, además de las relaciones tipo ratio empleadas en este estudio, con el fin de identificar configuraciones que permitan mejorar la capacidad predictiva del modelo sin perder interpretabilidad.
- 4) Emplear el modelo LASSO-3 preferentemente para la predicción de resistencias dosificadas alrededor de 210 kg/cm² a 350 kg/cm² siempre y cuando no haya acceso directo a un laboratorio, dado que en este rango se evaluó su capacidad predictiva con dosificaciones externas.

REFERENCIAS BIBLIOGRÁFICAS

- [1] S. Paudel, A. Pudasaini, R. K. Shrestha, y E. Kharel, «Compressive strength of concrete material using machine learning techniques», *Clean. Eng. Technol.*, vol. 15, n.º 4, p. 100661, ago. 2023, doi: 10.1016/j.clet.2023.100661.
- [2] S. O. Obam, A. S. Jagba, y P. T. Adeke, «Regression models for prediction of compressive and tensile concrete strength», *CEDTECH International Journal of Engineering & Applied Science*, vol. 5, pp. 7-25, jun. 2024, Accedido: 28 de marzo de 2026. [En línea]. Disponible en: https://www.researchgate.net/publication/393449460_REGRESSION_MODELS_FOR_PREDICTION_OF_COMPRESSIVE_AND_TENSILE_CONCRETE_STRENGTH#fullTextFileContent
- [3] L. María y R. Minotta, «Análisis predictivo y optimización de la resistencia a compresión del concreto mediante métodos avanzados de modelado estadístico.», Fundación Universitaria Los Libertadores, Bogotá, 2024. Accedido: 28 de marzo de 2026. [En línea]. Disponible en: <http://hdl.handle.net/11371/7240>
- [4] I. De La Roz Martínez y R. Puig Martínez, «Modelo matemático para predecir la resistencia a compresión del hormigón a 28 días », *Revista Cubana de Ingeniería*, vol. XII, n.º 1, pp. 58-66, 2021.
- [5] J. O. F. Reina, C. E. C. Vera, y D. O. S. Coello, «La gestión integral de residuos de construcción y demolición, un enfoque hacia la sostenibilidad de las ciudades», *South Florida Journal of Development*, vol. 4, n.º 6, pp. 2254-2277, sep. 2023, doi: 10.46932/sfjdv4n6-004.
- [6] M. S. Nikoopayan Tak, Y. Feng, y M. Mahgoub, «Advanced Machine Learning Techniques for Predicting Concrete Compressive Strength», *Infrastructures 2025, Vol. 10, Page 26*, vol. 10, n.º 2, p. 26, ene. 2025, doi: 10.3390/INFRASTRUCTURES10020026.
- [7] G. James, D. Witten, T. Hastie, y R. Tibshirani, *Statistics An Introduction to Statistical Learning*. Accedido: 2 de mayo de 2026. [En línea]. Disponible en: <http://www.springer.com/series/417>

- [8] A. Sivasubramanian, S. Arathy Krishna, D. H. Nair, K. Varma, R. Radhakrishnan, y D. Sathyan, «Experimental validation of compressive strength prediction using machine learning algorithm», *Mater. Today Proc.*, vol. 64, pp. 181-187, ene. 2022, doi: 10.1016/J.MATPR.2022.04.362.
- [9] K. Liu *et al.*, «Development of compressive strength prediction platform for concrete materials based on machine learning techniques», *Journal of Building Engineering*, vol. 80, p. 107977, dic. 2023, doi: 10.1016/J.JOBE.2023.107977.
- [10] H. Schreiberová, «Prediction of the compressive strength of concrete by machine learning regression models», Accedido: 28 de marzo de 2026. [En línea]. Disponible en: https://concrete.fsv.cvut.cz/phdworkshop/proceedings/2021/pdf/Schreiberova_Hana.pdf
- [11] H. Mohammad, M. Kharun, H. C. A. Tavares, y C. H. Martins, «Predicting Concrete Compressive Strength Using Machine Learning and the Theory of Substantial Motion», 2025, doi: 10.2139/SSRN.5352671.
- [12] M. Shaaban, M. Amin, S. Selim, y I. M. Riad, «Machine learning approaches for forecasting compressive strength of high-strength concrete», *Scientific Reports 2025 15:1*, vol. 15, n.º 1, pp. 25567-, jul. 2025, doi: 10.1038/s41598-025-10342-1.
- [13] A. D. Rivera Yaselga, «Despliegue, operaciones y accesibilidad utilizando soluciones de aprendizaje automático: engineering of machine learning operations.», Escuela Politécnica Nacional, Quito, 2025. Accedido: 22 de abril de 2026. [En línea]. Disponible en: <https://bibdigital.epn.edu.ec/handle/15000/26479>
- [14] A. Caiza, «Predicción de la resistencia a compresión en hormigón simple mediante un modelo de regresión lineal múltiple», Universidad Técnica de Ambato, Ambato, 2025. Accedido: 20 de abril de 2026. [En línea]. Disponible en: <https://repositorio.uta.edu.ec/handle/123456789/44090>
- [15] Norma Ecuatoriana de la Construcción, «Estructuras de Hormigón Armado», 2015. Accedido: 22 de abril de 2026. [En línea]. Disponible en: <https://www.mit.gob.ec/wp-content/uploads/downloads/2026/03/5.-NEC-SE-HM-Estructuras-de-Hormigon-Armado.pdf>

- [16] K. P. Cabello Solorzano, «Preprocesamiento de datos en aprendizaje automático supervisado: Técnicas de normalización», Universidad de Huelva & Universidad Internacional de Andalucía, 2023. Accedido: 22 de abril de 2026. [En línea]. Disponible en:
https://www.uhu.es/mecofin/documents/docencia/tfm/20222023/MECOFIN_20222023_tfm-CSKP_PDDE.pdf
- [17] D. Rodríguez Gómez, «Análisis de datos y Machine Learning», Universidad de Salamanca, Salamanca, 2023.
- [18] P. Bruce, A. Bruce, y Gedeck Peter, *Estadística práctica para ciencia de datos con R y Python*. Marcombo, 2022.
- [19] L. Moreno Gonzáles, «Herramientas avanzadas de análisis de datos de aplicación en Ingeniería Civil», Universidad de Cantabria, Santander, 2017. Accedido: 22 de abril de 2026. [En línea]. Disponible en:
<https://repositorio.unican.es/xmlui/bitstream/handle/10902/12684/Lucia%20Moreno%20Gonz%c3%a1lez-Paramo.pdf?sequence=1&isAllowed=y>
- [20] W. McKinney, «Data Structures for Statistical Computing in Python», *SciPy*, pp. 56-61, 2010, doi: 10.25080/MAJORA-92BF1922-00A.
- [21] E. Villavicencio-Caparó, M. Lima-Illescas, K. Cuenca-León, E. Patiño-Ramón, y E. Pacheco-Quito, «¿Cómo escoger la prueba estadística? Manejo de datos parte 2», *Odontología Activa Revista Científica*, vol. 8, n.º 2, pp. 53-66, may 2023, doi: 10.31984/OACTIVA.V8I2.885.
- [22] E. Temizhan, H. Mirtagioglu, y M. Mendes, «Which Correlation Coefficient Should Be Used for Investigating Relations between Quantitative Variables?», *American Scientific Research Journal for Engineering, Technology, and Sciences*, vol. 85, n.º 1, pp. 265-277, ene. 2022, Accedido: 30 de abril de 2026. [En línea]. Disponible en:
https://www.researchgate.net/publication/359579944_Which_Correlation_Coefficient_Should_Be_Used_for_Investigating_Relations_between_Quantitative_Variables
- [23] M. L. Waskom, «seaborn: statistical data visualization», *J. Open Source Softw.*, vol. 6, n.º 60, p. 3021, abr. 2021, doi: 10.21105/JOSS.03021.

- [24] A. M. Carranza Rodríguez, D. L. Carranza Monzón, y S. L. León Luyo, «Aplicación de las escalas de medición ordinal para interpretar coeficientes de la correlación en investigación científica», *Revista Científica Searching de Ciencias Humanas Y Sociales*, vol. 5, n.º 1, pp. 48-60, dic. 2023, doi: 10.46363/SEARCHING.V5I1.4.
- [25] J. Amat Rodrigo, «Correlación lineal con Python», Ciencia de Datos. Accedido: 15 de mayo de 2026. [En línea]. Disponible en: <https://cienciadedatos.net/documentos/pystats05-correlacion-lineal-python>
- [26] P. Singh, S. Singh, y M. Paprzycki, «Detection and elimination of multicollinearity in regression analysis», *International Journal of Knowledge-Based and Intelligent Engineering Systems*, vol. 27, n.º 1, pp. 105-111, 2023, doi: 10.3233/KES-221622.
- [27] X. Peng, Z. Zhuang, y Q. Yang, «Predictive Modeling of Compressive Strength for Concrete at Super Early Age», *Materials*, vol. 15, n.º 14, p. 4914, jul. 2022, doi: 10.3390/MA15144914.
- [28] S. Yu *et al.*, «Multiple linear regression models with natural logarithmic transformations of variables», *Zhonghua Yu Fang Yi Xue Za Zhi*, vol. 54, n.º 4, pp. 451-456, abr. 2020, doi: 10.3760/CMA.J.CN112150-20191030-00824.
- [29] Scikit-learn Developers, «Common pitfalls and recommended practices». Accedido: 2 de mayo de 2026. [En línea]. Disponible en: https://scikit-learn.org/stable/common_pitfalls.html
- [30] J. Bhattacharyya, «LASSO Regression – A Procedural Improvement», ene. 2025, doi: 10.2139/SSRN.5108591.
- [31] S. Elhishi, A. M. Elashry, y S. El-Metwally, «Unboxing machine learning models for concrete strength prediction using XAI», *Scientific Reports 2023 13:1*, vol. 13, n.º 1, pp. 19892-, nov. 2023, doi: 10.1038/s41598-023-47169-7.
- [32] M. M. Arias y <https://dialnet.unirioja.es/servlet/autor?codigo=1974722>, «Un baile épico. Técnicas de regularización en regresión múltiple.», *Revista electrónica AnestesiaR, ISSN-e 1989-4090, Vol. 16, Nº. 5, 2024*, vol. 16, n.º 5, p. 4, 2024, Accedido: 5 de mayo de 2026. [En línea]. Disponible en: <https://dialnet.unirioja.es/servlet/articulo?codigo=9587432&info=resumen&idioma=SP>

- [33] N. Sisamon Dolader, «Nuevas técnicas de regresión: métodos de regularización y otros - Repositorio Institucional de Documentos», Universidad de Zaragoza, 2021. Accedido: 5 de mayo de 2026. [En línea]. Disponible en: <https://zaguan.unizar.es/record/110347#>
- [34] L. Freijeiro-González, M. Febrero-Bande, y W. González-Manteiga, «A Critical Review of LASSO and Its Derivatives for Variable Selection Under Dependence Among Covariates», *International Statistical Review*, vol. 90, n.º 1, pp. 118-145, abr. 2022, doi: 10.1111/INSR.12469.
- [35] B. Gurung, K. N. Singh, A. Lama, y B. Gurung, «Least Absolute Shrinkage and Selection Operator (LASSO) Regression», en *Statistical Procedures for Analyzing Agricultural Data using R*, ICAR- Indian Institute of Rice Research, 2023, VIII, pp. 113-125. Accedido: 5 de mayo de 2026. [En línea]. Disponible en: <https://icar-iirr.org/books/Statistical%20Procedures%20for%20Analysing%20Agricultural%20Data%20using%20R.pdf>
- [36] Y. Wu y L. Wang, «A survey of tuning parameter selection for high-dimensional regression», *Annu. Rev. Stat. Appl.*, vol. 7, n.º Volume 7, 2020, pp. 209-226, mar. 2020, doi: 10.1146/ANNUREV-STATISTICS-030718-105038/CITE/REFWORKS.
- [37] Q. Bertrand y M. Massias, «Anderson acceleration of coordinate descent», *Proc. Mach. Learn. Res.*, vol. 130, pp. 1288-1296, nov. 2020, Accedido: 5 de mayo de 2026. [En línea]. Disponible en: <https://arxiv.org/pdf/2011.10065>
- [38] J. Friedman, T. Hastie, y R. Tibshirani, «Regularization Paths for Generalized Linear Models via Coordinate Descent», *J. Stat. Softw.*, vol. 33, n.º 1, p. 1, 2010, doi: 10.18637/jss.v033.i01.
- [39] C. R. Harris *et al.*, «Array programming with NumPy», *Nature* 2020 585:7825, vol. 585, n.º 7825, pp. 357-362, sep. 2020, doi: 10.1038/s41586-020-2649-2.
- [40] T. O. Hodson, «Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not», *Geosci. Model Dev.*, vol. 15, n.º 14, pp. 5481-5487, jul. 2022, doi: 10.5194/GMD-15-5481-2022.
- [41] D. Chicco, M. J. Warrens, y G. Jurman, «The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis

- evaluation», *PeerJ Comput. Sci.*, vol. 7, pp. 1-24, jul. 2021, doi: 10.7717/PEERJ-CS.623/SUPP-1.
- [42] P. Manandhar, H. Rafiq, E. Rodriguez-Ubinas, y T. Palpanas, «New Forecasting Metrics Evaluated in Prophet, Random Forest, and Long Short-Term Memory Models for Load Forecasting», 2024, doi: 10.3390/en17236131.
- [43] P. Jagadesh, J. de Prado-Gil, N. Silva-Monteiro, y R. Martínez-García, «Assessing the compressive strength of self-compacting concrete with recycled aggregates from mix ratio using machine learning approach», *Journal of Materials Research and Technology*, vol. 24, pp. 1483-1498, may 2023, doi: 10.1016/J.JMRT.2023.03.037.
- [44] C. D. . Lewis, «Industrial and business forecasting methods : a practical guide to exponential smoothing and curve fitting», p. 143, 1982.
- [45] «Áridos. Determinación de la densidad, densidad relativa (gravedad específica) y absorción del árido fino», Quito, 2010.
- [46] «Áridos. Determinación de la densidad, densidad relativa (gravedad específica) y absorción del árido grueso», Quito, 2010.
- [47] A. Almeida Domínguez, «Análisis comparativo de métodos de diseño de mezclas de un hormigón de alta resistencia conformado por agregados procedentes de la cantera de Pintag», Universidad Politécnica Salesiana, Quito, 2019. Accedido: 9 de mayo de 2026. [En línea]. Disponible en: <https://dspace.ups.edu.ec/bitstream/123456789/18189/1/UPS%20-%20ST004397.pdf>

ANEXOS

Anexo 1: Código de exploración inicial y análisis de correlación entre predictores

```
# -----
#  TEMA: EXPLORACIÓN INICIAL Y ANÁLISIS DE CORRELACIÓN
#  Dataset original compuesto por 32 variables iniciales
#  Elaborado por: Karen Mosquera
#  Fecha: 12/05/2026
# -----

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

# — CARGA DEL ARCHIVO -----

RUTA_ARCHIVO = '/content/BASE GENERAL 7_14_28 INICIAL CON 32 VARIABLES
.xlsx' # <— MODIFICAR

extension = RUTA_ARCHIVO.split('.')[ -1].lower()
if extension in ['xlsx', 'xls']:
    df = pd.read_excel(RUTA_ARCHIVO)
elif extension == 'csv':
    df = pd.read_csv(RUTA_ARCHIVO)
else:
    raise ValueError(f"Formato '{extension}' no soportado. Usa .xlsx o
.csv")

print(f" Archivo cargado: {df.shape[0]} filas × {df.shape[1]} columnas")

# — 1. EXPLORACIÓN INICIAL -----

print("\n" + "=" * 65)
print("  1. EXPLORACIÓN INICIAL")
print("=" * 65)
print("\n Primeras filas del dataset:")
```

```

print(df.head())

print("\n Información del dataset:")

print(df.info())

# Eliminar nulos
nulos_por_columna = df.isnull().sum()
filas_con_nulos    = df.isnull().any(axis=1).sum()
if filas_con_nulos > 0:
    print(f"\n  Valores nulos detectados:")
    print(nulos_por_columna[nulos_por_columna > 0])
    df.dropna(inplace=True)
    print(f"      → {filas_con_nulos}  filas  eliminadas.  Dataset:
{df.shape[0]}  filas.")
else:
    print("\n No se detectaron valores nulos.")

# Estadísticos descriptivos sobre datos limpios
pd.set_option('display.max_columns', None)
pd.set_option('display.width', None)
pd.set_option('display.float_format', '{:.3f}'.format)

print("\n Estadísticos descriptivos:")
desc    =    df.describe().loc[['count',    'mean',    'std',    'min',
'max']].T.round(3)
desc['count'] = desc['count'].astype(int)
print(desc.to_string())

# Distribución de muestras por edad
print("\n Distribución de muestras por edad de ensayo:")
print(f"\n    {'Edad (días)':<15} {'N muestras':>12} {'Porcentaje':>12}")
print("    " + "-" * 42)

# Detectar columna de edad automáticamente
col_edad = None

```

```

for col in df.columns:
    if 'edad' in col.lower() or 'age' in col.lower():
        col_edad = col
        break

if col_edad:
    conteo = df[col_edad].value_counts().sort_index()
    for edad, n in conteo.items():
        pct = n / len(df) * 100
        print(f"    {edad:<15} {n:>12} {pct:>11.1f}%")
    print(f"    {'TOTAL':<15} {len(df):>12} {'100.0%':>12}")
else:
    print(" No se encontró columna de edad. Verifica el nombre.")

# — 2. ANÁLISIS DE CORRELACIÓN ENTRE PREDICTORES —————
print("\n" + "=" * 65)
print("  2. ANÁLISIS DE MULTICOLINEALIDAD ENTRE PREDICTORES")
print("=" * 65)

COLUMNA_OBJETIVO = 'fc'
UMBRAL            = 0.90

vars_predictoras = [c for c in df.columns if c != COLUMNA_OBJETIVO]
corr_matrix      = df[vars_predictoras].corr()

print(f"\n Umbral de correlación alta: |r| > {UMBRAL}")
print(f" Total de predictores analizados: {len(vars_predictoras)}")

pares = []
for i in range(len(corr_matrix.columns)):

```

```

for j in range(i+1, len(corr_matrix.columns)):
    val = corr_matrix.iloc[i, j]
    if abs(val) > UMBRAL:
        var1 = corr_matrix.columns[i]
        var2 = corr_matrix.columns[j]
        pares.append({
            'Variable 1' : var1,
            'Variable 2' : var2,
            'Correlación': round(val, 4),
        })
df_pares = pd.DataFrame(pares)
if df_pares.empty:
    print(f"\n No se encontraron pares con |r| > {UMBRAL}")
else:
    print(f"\n {'Variable 1':<20} {'Variable 2':<20} {'r':>8}")
    print(" " + "-" * 52)
    for _, row in df_pares.iterrows():
        print(f" {row['Variable 1']:<20} {row['Variable 2']:<20} "
              f"{row['Correlación']:>8.4f}")
    print(f"\n Total de pares con |r| > {UMBRAL}: {len(df_pares)}")

# — 3. VISUALIZACIÓN DE CORRELACIÓN —————
if not df_pares.empty:
    vars_problematicas = set()
    for _, row in df_pares.iterrows():
        vars_problematicas.add(row['Variable 1'])
        vars_problematicas.add(row['Variable 2'])
    vars_problematicas = sorted(list(vars_problematicas))

    corr_sub = corr_matrix.loc[vars_problematicas, vars_problematicas]

```

```

fig, ax = plt.subplots(figsize=(12, 10))
fig.suptitle(
    f'Variables con  $|r| > \{UMBRAL\}$  – Multicolinealidad alta\n'
    f'Dataset:  $\{df.shape[0]\}$  muestras  $\times \{len(vars\_predictoras)\}$ 
predictores',
    fontsize=13, fontweight='bold'
)
sns.heatmap(
    corr_sub,
    ax=ax,
    cmap='coolwarm',
    center=0,
    vmin=-1, vmax=1,
    annot=True,
    fmt='.2f',
    linewidths=0.5,
    linecolor='white',
    cbar_kws={'label': 'Coeficiente de correlación de Pearson (r)',
'shrink': 0.8},
    annot_kws={'size': 9}
)
ax.set_title(f'Pares de variables con  $|r| > \{UMBRAL\}$ ', fontsize=11)
ax.tick_params(axis='both', labelsize=9)

for i in range(len(vars_problematicas)):
    for j in range(len(vars_problematicas)):
        if i != j and abs(corr_sub.iloc[i, j]) > UMBRAL:
            ax.add_patch(plt.Rectangle(
                (j, i), 1, 1,
                fill=False, edgecolor='red', linewidth=2.5, zorder=5
            ))

```

```
        ))  
plt.tight_layout()  
plt.savefig('correlacion_predictores.png',      dpi=150,  
bbox_inches='tight')  
plt.show()  
print("\n Gráfico guardado como 'correlacion_predictores.png'")  
print("\n La decisión de eliminar variables queda a criterio del  
investigador.")
```

Anexo 2: Código de correlación de predictores con la variable objetivo fc

```
# -----
# CORRELACIÓN DE PREDICTORES CON LA VARIABLE OBJETIVO fc
# Dataset con 25 variables seleccionadas
# Elaborado por: Karen Mosquera
# Fecha: 12/05/2026
# -----

import numpy as np
import pandas as pd

# — CARGA DEL ARCHIVO -----
RUTA_ARCHIVO = '/content/BASE GENERAL 7_14_28 VARIABLES SELECCIONADAS.xlsx' # <— MODIFICAR

extension = RUTA_ARCHIVO.split('.')[ -1].lower()
if extension in ['xlsx', 'xls']:
    df = pd.read_excel(RUTA_ARCHIVO)
elif extension == 'csv':
    df = pd.read_csv(RUTA_ARCHIVO)
else:
    raise ValueError(f"Formato '{extension}' no soportado. Usa .xlsx o .csv")

print(f" Archivo cargado: {df.shape[0]} filas × {df.shape[1]} columnas")
print(f" Columnas disponibles: {df.columns.tolist()}")

# — LIMPIEZA BÁSICA -----
df.dropna(inplace=True)
print(f" Dataset tras eliminar nulos: {df.shape[0]} filas")

COLUMNA_OBJETIVO = 'fc' # <— MODIFICAR SI ES NECESARIO
```

```

# — ELIMINAR VARIABLES CON VARIANZA CERO —————
vars_varianza_cero = [col for col in df.columns
                      if col != COLUMNA_OBJETIVO and df[col].var() == 0]
if vars_varianza_cero:
    print("\n Variables con varianza cero excluidas:", vars_varianza_cero)
    df = df.drop(columns=vars_varianza_cero)
else:
    print("\n No se detectaron variables con varianza cero.")

# — CORRELACIÓN CON fc —————
vars_predictoras = [c for c in df.columns if c != COLUMNA_OBJETIVO]
corr_fc = df[vars_predictoras].corrwith(df[COLUMNA_OBJETIVO])
corr_fc_sorted = corr_fc.reindex(corr_fc.abs().sort_values(ascending=False).index)

print("\n Correlación de Pearson con f'c (ordenada por valor absoluto):")
print(f"\n  {'Variable':<25} {'r con fc':>10}")
print("  " + "-" * 38)
for var, val in corr_fc_sorted.items():
    print(f"  {var:<25} {val:>10.3f}")

```

Anexo 3: Código para entrenamiento del modelo LASSO

```
# -----
#  TEMA: MODELO LASSO - RESISTENCIA A COMPRESIÓN DEL HORMIGÓN
#  Entrenamiento de modelos
#  Elaborado por: Karen Mosquera
#  Fecha: 12/05/2026
# -----

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import scipy.stats as stats
import warnings
warnings.filterwarnings('ignore')

from sklearn.linear_model import LassoCV, Lasso
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import r2_score, mean_squared_error

# — 1. RUTA DEL ARCHIVO -----
RUTA_ARCHIVO = '/content/BASE GENERAL 7_14_28 DATASET MODELO .xlsx'
# <— MODIFICAR

NOMBRE_MODELO = 'LASSO-3'  # <— CAMBIAR POR CADA MODELO

print("=" * 60)
print("  MODELO LASSO – RESISTENCIA A COMPRESIÓN DEL HORMIGÓN")
print("=" * 60)

extension = RUTA_ARCHIVO.split('.')[ -1].lower()
```

```

if extension in ['.xlsx', '.xls']:
    df = pd.read_excel(RUTA_ARCHIVO)
elif extension == '.csv':
    df = pd.read_csv(RUTA_ARCHIVO)
else:
    raise ValueError(f"Formato '{extension}' no soportado. Usa .xlsx o .csv")

print(f"\n Archivo cargado: '{RUTA_ARCHIVO}'")
print(f" Dimensiones: {df.shape[0]} filas × {df.shape[1]} columnas")

# Verificar nulos
nulos = df.isnull().sum()
if nulos.any():
    print(f"\n Valores nulos detectados:\n{nulos[nulos > 0]}")
    df.dropna(inplace=True)
    print(f" → Dataset resultante: {df.shape[0]} filas.")
else:
    print(" Sin valores nulos.")

# — 2. DEFINICIÓN DE VARIABLES —————
print("\n" + "=" * 60)
print(" 2. DEFINICIÓN DE VARIABLES")
print("=" * 60)

COLUMNA_OBJETIVO = 'fc' # <— MODIFICAR si la columna tiene otro nombre

COLUMNAS_EXCLUIR = [COLUMNA_OBJETIVO]

X = df.drop(columns=COLUMNAS_EXCLUIR)

```

```

y = df[COLUMNA_OBJETIVO]

print(f"\n  Variable objetivo (Y) : '{COLUMNA_OBJETIVO}')"
print(f"  Variables predictoras (X): {list(X.columns)}")
print(f"  Número de predictores: {X.shape[1]}")

# — 3. DIVISIÓN 80% ENTRENAMIENTO / 20% PRUEBA —————
# random_state=42 garantiza reproducibilidad.
# No se requiere conjunto de validación adicional porque
# LassoCV realiza validación cruzada interna para elegir  $\lambda$ .

print("\n" + "=" * 60)
print("  3. DIVISIÓN DE DATOS (80% entrenamiento / 20% prueba)")
print("=" * 60)

X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.20, random_state=42
)

print(f"\n  Total      : {len(df)} muestras")
print(f"  Entrena    : {len(X_train)} muestras  (80%)")
print(f"  Prueba     : {len(X_test)} muestras  (20%)")

# — 4. ESTANDARIZACIÓN —————
# REGLA CRÍTICA: StandardScaler se ajusta SOLO con los datos
# de entrenamiento (fit_transform) y luego se aplica a los
# datos de prueba (transform). Hacerlo al revés causaría
# data leakage (filtración de información del futuro).

```

```

print("\n" + "=" * 60)
print(" 4. ESTANDARIZACIÓN (StandardScaler)")
print("=" * 60)

scaler = StandardScaler()
X_train_sc = scaler.fit_transform(X_train)
X_test_sc = scaler.transform(X_test)

print("\n  fit_transform → conjunto de entrenamiento")
print("  transform      → conjunto de prueba (sin data leakage)")

# — 5. SELECCIÓN DE  $\lambda$  ÓPTIMO (LassoCV) —————
# Se define un rango explícito de 1000 valores entre 0.0001 y 100
# en escala logarítmica.
# cv=3: con el tamaño del dataset, 3 folds generan subconjuntos
# de validación más representativos que 5 folds.

print("\n" + "=" * 60)
print(" 5. SELECCIÓN DE  $\lambda$  ÓPTIMO (LassoCV, cv=3)")
print("=" * 60)
print("\n  Ejecutando validación cruzada...\n")

alphas = np.logspace(-4, 2, 1000) # 1000 valores entre 0.0001 y 100

lasso_cv = LassoCV(
    alphas=alphas,
    cv=3,
    random_state=42,
    max_iter=10000,

```

```

        n_jobs=-1
    )
    lasso_cv.fit(X_train_sc, y_train)

    lambda_optimo = lasso_cv.alpha_
    print(f" λ óptimo seleccionado: {lambda_optimo:.6f}")
    print(f"   (rango buscado: [{alphas.min():.4f}, {alphas.max():.4f}], 1000
valores)")

# — 6. ENTRENAMIENTO DEL MODELO FINAL —————
print("\n" + "=" * 60)
print("  6. ENTRENAMIENTO DEL MODELO FINAL")
print("=" * 60)

modelo_lasso = Lasso(alpha=lambda_optimo, max_iter=10000)
modelo_lasso.fit(X_train_sc, y_train)

coeficientes = pd.Series(
    modelo_lasso.coef_,
    index=X.columns,
    name='Coeficiente'
).sort_values(key=abs, ascending=False)

coef_activos = (modelo_lasso.coef_ != 0).sum()
coef_nulos   = (modelo_lasso.coef_ == 0).sum()

print(f"\n   Intercepto                : {modelo_lasso.intercept_:.4f}")
print(f"   Predictores activos (≠0) : {coef_activos}")
print(f"   Predictores eliminados   : {coef_nulos}")
print(f"\n   Coeficientes ordenados por magnitud:")

```

```

print(coeficientes.round(3).to_string())

# — ECUACIÓN DEL MODELO —————
print("\n" + "-" * 60)
print("  ECUACIÓN DEL MODELO (variables estandarizadas)")
print("-" * 60)

# Construir términos de la ecuación solo con coeficientes activos
terminos = []
for var, coef in coeficientes.items():
    if coef != 0:
        signo = "+" if coef > 0 else "-"
        terminos.append(f"{signo} {abs(coef):.3f}({var})")

# Imprimir ecuación formateada con salto de línea cada 3 términos
ecuacion = f"\n  fc = {modelo_lasso.intercept_:.3f}\n"
for i, t in enumerate(terminos):
    if i % 3 == 0:
        ecuacion += "\n      "
    ecuacion += f" {t}"
ecuacion += " + ε"
print(ecuacion)

# — 7. PREDICCIONES Y MÉTRICAS —————
# Se evalúa el modelo en ambos conjuntos para detectar
# posible sobreajuste (overfitting) o subajuste (underfitting).
# R2 mide la varianza explicada (1 = perfecto).
# RMSE está en las mismas unidades que Y (kg/cm2).
# MAPE expresa el error como porcentaje del valor real.

```

```

print("\n" + "=" * 60)
print(" 7. MÉTRICAS DE EVALUACIÓN")
print("=" * 60)

y_pred_train = modelo_lasso.predict(X_train_sc)
y_pred_test  = modelo_lasso.predict(X_test_sc)

def calcular_metricas(y_real, y_pred, nombre):
    r2 = r2_score(y_real, y_pred)
    rmse = np.sqrt(mean_squared_error(y_real, y_pred))
    mask = np.array(y_real) != 0
    mape = np.mean(np.abs((np.array(y_real)[mask] -
np.array(y_pred)[mask])
                                / np.array(y_real)[mask])) * 100
    print(f"\n [{nombre}]")
    print(f" R² = {r2:.3f} ({'excelente' if r2>=0.90 else 'aceptable'
if r2>=0.75 else 'revisar'})")
    print(f" RMSE = {rmse:.3f} kg/cm²")
    print(f" MAPE = {mape:.3f} %")
    return r2, rmse, mape

r2_tr, rmse_tr, mape_tr = calcular_metricas(y_train, y_pred_train,
"ENTRENAMIENTO")

r2_te, rmse_te, mape_te = calcular_metricas(y_test, y_pred_test,
"PRUEBA")

dif_r2 = abs(r2_tr - r2_te)
print(f"\n Diferencia R² (train-test): {dif_r2:.3f}", end=" ")
print("→ Ajuste generalizable" if dif_r2 < 0.05 else "→ Posible
sobreajuste")

```

```

# — 8. VISUALIZACIONES —————
# — 8A. Coeficientes LASSO —————

fig1, ax1 = plt.subplots(figsize=(10, 6))

colores = ['#1a6bb5' if c > 0 else '#c0392b' for c in coeficientes]

barras = ax1.barh(coeficientes.index, coeficientes.values,
color=colores,

                    edgecolor='white', height=0.6)

ax1.axvline(0, color='black', linewidth=0.8, linestyle='--')
ax1.set_xlabel('Coeficiente estandarizado', fontsize=11)
ax1.set_title('Coeficientes del modelo LASSO\n'
              '(azul = positivo | rojo = negativo | ausente = eliminado
por L1)',

              fontsize=11)

ax1.tick_params(axis='y', labelsize=10)

for barra, val in zip(barras, coeficientes.values):
    if abs(val) > 0.001:
        ax1.text(val + 0.005*np.sign(val),
barra.get_y()+barra.get_height()/2,
                  f'{val:.3f}', va='center', ha='left' if val>0 else
'right', fontsize=8)

ax1.grid(axis='x', alpha=0.3)

plt.tight_layout()

plt.savefig('coeficientes_lasso.png', dpi=150, bbox_inches='tight')

plt.show()


# — 8B. Predicho vs Real (entrenamiento) —————

fig3, ax3 = plt.subplots(figsize=(6, 6))

lim = [min(y_train.min(), y_pred_train.min())-2,
        max(y_train.max(), y_pred_train.max())+2]

ax3.scatter(y_train, y_pred_train, alpha=0.55, color='#1a6bb5',
            s=30, edgecolors='white', linewidths=0.3)

```

```

ax3.plot(lim, lim, 'r--', linewidth=1.2, label='Predicción perfecta')
ax3.set_xlim(lim); ax3.set_ylim(lim)
ax3.set_xlabel('Resistencia real (kg/cm²)', fontsize=10)
ax3.set_ylabel('Resistencia predicha (kg/cm²)', fontsize=10)
ax3.set_title(f'{NOMBRE_MODELO} - Predicho vs Real (Entrenamiento)\nR² =
{r2_tr:.4f}', fontsize=11)
ax3.legend(fontsize=8)
ax3.grid(alpha=0.3)
plt.tight_layout()
plt.savefig('predicho_vs_real_train.png', dpi=150, bbox_inches='tight')
plt.show()

```

```

# — 8C. Predicho vs Real (prueba) —————
fig4, ax4 = plt.subplots(figsize=(6, 6))
lim2 = [min(y_test.min(), y_pred_test.min())-2,
        max(y_test.max(), y_pred_test.max())+2]
ax4.scatter(y_test, y_pred_test, alpha=0.65, color='#27ae60',
            s=35, edgecolors='white', linewidths=0.3)
ax4.plot(lim2, lim2, 'r--', linewidth=1.2, label='Predicción perfecta')
ax4.set_xlim(lim2); ax4.set_ylim(lim2)
ax4.set_xlabel('Resistencia real (kg/cm²)', fontsize=10)
ax4.set_ylabel('Resistencia predicha (kg/cm²)', fontsize=10)
ax4.set_title(f'{NOMBRE_MODELO} - Predicho vs Real (Prueba)\nR² =
{r2_te:.4f}', fontsize=11)
ax4.legend(fontsize=8)
ax4.grid(alpha=0.3)
plt.tight_layout()
plt.savefig('predicho_vs_real_test.png', dpi=150, bbox_inches='tight')
plt.show()

```

```

# — 8D. Q-Q Plot de residuales —————
fig5, ax5 = plt.subplots(figsize=(6, 6))

```

```

residuales = y_test.values - y_pred_test
stats.probplot(residuales, dist='norm', plot=ax5)
ax5.set_title(f'{NOMBRE_MODELO} - Q-Q Plot de residuales
(prueba)\n(normalidad de errores)', fontsize=11)
ax5.get_lines()[0].set(color='#1a6bb5', markersize=4, alpha=0.7)
ax5.get_lines()[1].set(color='red', linewidth=1.5)
ax5.grid(alpha=0.3)
plt.tight_layout()
plt.savefig('qqplot_residuales.png', dpi=150, bbox_inches='tight')
plt.show()

```

```

print("\n Gráficos guardados por separado:")
print("    • coeficientes_lasso.png")
print("    • curva_regularizacion.png")
print("    • predicho_vs_real_train.png")
print("    • predicho_vs_real_test.png")
print("    • qqplot_residuales.png")

```

```

# — 9. RESUMEN FINAL —————
print("\n" + "=" * 60)
print(" 9. RESUMEN FINAL DEL MODELO")
print("=" * 60)

```

```

resumen = pd.DataFrame({
    'Conjunto'      : ['Entrenamiento', 'Prueba'],
    'N muestras'    : [len(X_train), len(X_test)],
    'R²'            : [round(r2_tr, 3), round(r2_te, 3)],
    'RMSE (kg/cm²)': [round(rmse_tr, 3), round(rmse_te, 3)],
    'MAPE (%)'      : [round(mape_tr, 3), round(mape_te, 3)]
})

```

```

print(resumen.to_string(index=False))
print(f"\n   $\lambda$  óptimo (LassoCV)      : {lambda_optimo:.6f}")
print(f"      Rango buscado                  : [{alphas.min():.3f},
{alphas.max():.4f}] - 1000 valores")
print(f"  Predictores seleccionados: {coef_activos} de {X.shape[1]}")
print(f"  Predictores eliminados   : {coef_nulos}")
print("\n" + "=" * 60)
print("  FIN DEL ANÁLISIS")
print("=" * 60)

```

Anexo 4: Formato para implementación del modelo óptimo para predicción de f/c

[illegible]

Anexo 5: Formato base para la recopilación de información

[illegible]

Anexo 6: Información recopilada para la base de datos

[illegible]

Anexo 7: Base de datos con 32 variables

fc	Asent_horm igon (cm)	Dens_ceme nto (gr/cm³)	MF_af	TM_af (cm)	TNM_af (cm)	DAS_af (kg/m²)	DAC_af (kg/m²)	Porc_hum _af %	Porc_abs_	DA_af (kg/m²)	TM_ag "	TNM_ag "	DAS_ag (kg/m²)	DAC_ag (kg/m²)	Porc_hum _ag %	Porc_abs_a g %	DA_ag (kg/m²)	Porc_opt _af %	Porc_opt _ag %	DO_mezcla (kg/m³)	DM_mezcla (kg/m²)	Agua (kg)	Cemento (kg)	Arena (kg)	Grava (kg)	Agua_corr (kg)	Cemento_c orr (kg)	Arena_corr (kg)	Grava_corr (kg)	a/c	Edad (días)
208.330	7.500	2.910	3.000	0.187	0.093	1440.000	1520.000	0.130	1.420	2587.418	1.500	0.748	1286.667	1385.000	0.130	1.720	2621.145	0.400	0.600	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	14
251.730	7.500	2.910	3.000	0.187	0.093	1440.000	1520.000	0.130	1.420	2587.418	1.500	0.748	1286.667	1385.000	0.130	1.720	2621.145	0.400	0.600	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	28
138.680	6.000	2.931	2.740	0.374	0.093	1556.400	1699.900	1.990	1.120	2692.859	2.000	1.000	1568.600	1738.800	0.220	0.770	2670.497	0.380	0.620	1900.000	2002.000	185.960	320.621	722.971	1169.535	185.960	320.621	722.971	1169.535	0.580	7
208.190	6.000	2.931	2.740	0.374	0.093	1556.400	1699.900	1.990	1.120	2692.859	2.000	1.000	1568.600	1738.800	0.220	0.770	2670.497	0.380	0.620	1900.000	2002.000	185.960	320.621	722.971	1169.535	185.960	320.621	722.971	1169.535	0.580	28
155.810	8.000	2.890	2.590	0.374	0.187	1609.000	1702.000	1.675	2.020	2915.367	2.000	1.500	1388.000	1486.000	0.910	1.320	2598.830	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	7
171.180	8.000	2.890	2.590	0.374	0.187	1609.000	1702.000	1.675	2.020	2915.367	2.000	1.500	1388.000	1486.000	0.910	1.320	2598.830	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	14
211.800	8.000	2.890	2.590	0.374	0.187	1609.000	1702.000	1.675	2.020	2915.367	2.000	1.500	1388.000	1486.000	0.910	1.320	2598.830	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	28
146.810	6.250	2.793	2.598	0.374	0.093	1473.000	1527.000	5.080	1.880	2427.349	1.000	0.748	1373.000	1495.000	2.970	0.710	2642.716	0.450	0.550	1841.000	1844.000	197.661	340.795	742.175	991.330	197.661	340.795	742.175	991.330	0.580	7
172.860	6.250	2.793	2.598	0.374	0.093	1473.000	1527.000	5.080	1.880	2427.349	1.000	0.748	1373.000	1495.000	2.970	0.710	2642.716	0.450	0.550	1841.000	1844.000	197.661	340.795	742.175	991.330	197.661	340.795	742.175	991.330	0.580	14
196.700	6.250	2.793	2.598	0.374	0.093	1473.000	1527.000	5.080	1.880	2427.349	1.000	0.748	1373.000	1495.000	2.970	0.710	2642.716	0.450	0.550	1841.000	1844.000	197.661	340.795	742.175	991.330	197.661	340.795	742.175	991.330	0.580	28
210.000	7.500	2.900	3.000	0.187	0.093	1470.000	1570.000	0.130	1.920	2592.095	2.000	1.000	1330.000	1440.000	0.130	1.720	2621.145	0.360	0.640	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	28
154.090	6.000	2.860	2.667	0.375	0.187	1537.000	1634.000	2.668	2.615	2551.546	1.000	0.748	1382.000	1430.000	1.201	2.295	2627.681	0.370	0.590	1839.000	1842.000	210.297	362.580	625.717	1100.074	210.297	362.580	625.717	1100.074	0.580	7
205.250	6.000	2.860	2.667	0.375	0.187	1537.000	1634.000	2.668	2.615	2551.546	1.000	0.748	1382.000	1430.000	1.201	2.295	2627.681	0.370	0.590	1839.000	1842.000	210.297	362.580	625.717	1100.074	210.297	362.580	625.717	1100.074	0.580	14
216.710	6.000	2.860	2.667	0.375	0.187	1537.000	1634.000	2.668	2.615	2551.546	1.000	0.748	1382.000	1430.000	1.201	2.295	2627.681	0.370	0.590	1839.000	1842.000	210.297	362.580	625.717	1100.074	210.297	362.580	625.717	1100.074	0.580	28
158.360	7.400	2.821	2.371	0.187	0.093	1460.000	1614.000	2.720	1.970	2632.204	1.500	1.000	1324.000	1449.000	0.320	2.670	2513.432	0.460	0.540	1938.000	1951.100	176.000	309.128	864.000	972.000	176.000	309.128	864.000	972.000	0.569	7
200.480	7.400	2.821	2.371	0.187	0.093	1460.000	1614.000	2.720	1.970	2632.204	1.500	1.000	1324.000	1449.000	0.320	2.670	2513.432	0.460	0.540	1938.000	1951.100	176.000	309.128	864.000	972.000	176.000	309.128	864.000	972.000	0.569	14
246.000	7.400	2.821	2.371	0.187	0.093	1460.000	1614.000	2.720	1.970	2632.204	1.500	1.000	1324.000	1449.000	0.320	2.670	2513.432	0.460	0.540	1938.000	1951.100	176.000	309.128	864.000	972.000	176.000	309.128	864.000	972.000	0.569	28
166.830	7.500	2.760	3.360	0.375	0.187	1560.000	1730.000	0.210	1.000	2568.143	1.500	1.000	1370.000	1490.000	0.660	4.330	2494.932	0.360	0.640	1840.000	1850.000	194.690	341.560	633.440	1090.200	194.690	341.560	633.440	1090.200	0.570	7
199.040	7.500	2.760	3.360	0.375	0.187	1560.000	1730.000	0.210	1.000	2568.143	1.500	1.000	1370.000	1490.000	0.660	4.330	2494.932	0.360	0.640	1840.000	1850.000	194.690	341.560	633.440	1090.200	194.690	341.560	633.440	1090.200	0.570	14
244.910	7.500	2.760	3.360	0.375	0.187	1560.000	1730.000	0.210	1.000	2568.143	1.500	1.000	1370.000	1490.000	0.660	4.330	2494.932	0.360	0.640	1840.000	1850.000	194.690	341.560	633.440	1090.200	194.690	341.560	633.440	1090.200	0.570	28
219.643	3.000	2.640	2.760	0.375	0.187	1550.000	1680.000	3.980	1.130	2505.485	2.000	1.500	1710.000	1840.000	1.010	4.750	2386.830	0.260	0.740	1717.000	1728.000	170.690	341.380	456.820	1238.020	170.690	341.380	456.820	1238.020	0.500	7
267.067	3.000	2.640	2.760	0.375	0.187	1550.000	1680.000	3.980	1.130	2505.485	2.000	1.500	1710.000	1840.000	1.010	4.750	2386.830	0.260	0.740	1717.000	1728.000	170.690	341.380	456.820	1238.020	170.690	341.380	456.820	1238.020	0.500	14
345.843	3.000	2.640	2.760	0.375	0.187	1550.000	1680.000	3.980	1.130	2505.485	2.000	1.500	1710.000	1840.000	1.010	4.750	2386.830	0.260	0.740	1717.000	1728.000	170.690	341.380	456.820	1238.020	170.690	341.380	456.820	1238.020	0.500	28
214.214	5.000	2.640	2.440	0.187	0.093	1560.000	1670.000	2.590	1.830	2593.095	1.500	1.000	1230.000	1350.000	3.040	5.150	2507.003	0.360	0.640	1818.000	1854.000	170.690	341.380	675.100	1125.950	170.690	341.380	675.100	1125.950	0.500	7
270.799	5.000	2.640	2.440	0.187	0.093	1560.000	1670.000	2.590	1.830	2593.095	1.500	1.000	1230.000	1350.000	3.040	5.150	2507.003	0.360	0.640	1818.000	1854.000	170.690	341.380	675.100	1125.950	170.690	341.380	675.100	1125.950	0.500	14
305.558	5.000	2.640	2.440	0.187	0.093	1560.000	1670.000	2.590	1.830	2593.095	1.500	1.000	1230.000	1350.000	3.040	5.150	2507.003	0.360	0.640	1818.000	1854.000	170.690	341.380	675.100	1125.950	170.690	341.380	675.100	1125.950	0.500	28
204.918	3.000	2.640	2.980	0.375	0.187	1600.000	1700.000	0.730	3.020	2505.502	0.748	0.748	1740.000	1880.000	0.520	2.410	2569.899	0.360	0.640	1711.000	1784.000	169.150	345.210	703.300	1082.060	169.150	345.210	703.300	1082.060	0.490	7
272.112	3.000	2.640	2.980	0.375	0.187	1600.000	1700.000	0.730	3.020	2505.502	0.748	0.748	1740.000	1880.000	0.520	2.410	2569.899	0.360	0.640	1711.000	1784.000	169.150	345.210	703.300	1082.060	169.150	345.210	703.300	1082.060	0.490	14
326.676	3.000	2.640	2.980	0.375	0.187	1600.000	1700.000	0.730	3.020	2505.502	0.748	0.748	1740.000	1880.000	0.520	2.410	2569.899	0.360	0.640	1711.000	1784.000	169.150	345.210	703.300	1082.060	169.150	345.210	703.300	1082.060	0.490	28
172.546	7.500	2.920	2.834	0.374	0.187	1410.000	1560.000	0.551	2.100	2568.619	1.000	1.000	1440.000	1550.000	0.524	2.930	2578.507	0.400	0.600	1810.000	1820.000	215.380	377.860	680.510	1015.450	215.380	377.860	680.510	1015.450	0.570	7
204.666	7.500	2.920	2.834	0.374	0.187	1410.000	1560.000	0.551	2.100	2568.619	1.000	1.000	1440.000	1550.000	0.524	2.930	2578.507	0.400	0.600	1810.000	1820.000	215.380	377.860	680.510	1015.450	215.380	377.860	680.510	1015.450	0.570	14
241.016	7.500	2.920	2.834	0.374	0.187	1410.000	1560.000	0.551	2.100	2568.619	1.000	1.000	1440.000	1550.000	0.524	2.930	2578.507	0.400	0.600	1810.000	1820.000	215.380	377.860	680.510	1015.450	215.380	377.860	680.510	1015.450	0.570	28
155.810	4.000	2.955	2.300	0.374	0.187	1609.000	1702.000	1.675	2.020	2629.151	2.000	1.500	1388.000	1486.000	0.910	1.320	2671.545	0.380	0.620	1842.000	1857.000</										

154.910	7.000	2.912	2.350	0.187	0.093	1352.000	1481.000	0.551	1.050	2730.740	2.000	1.500	1367.000	1496.000	0.524	0.640	2649.724	0.360	0.640	1880.000	1890.000	211.660	377.960	643.180	1119.540	211.660	377.960	643.180	1119.540	0.560	7
208.120	7.000	2.912	2.350	0.187	0.093	1352.000	1481.000	0.551	1.050	2730.740	2.000	1.500	1367.000	1496.000	0.524	0.640	2649.724	0.360	0.640	1880.000	1890.000	211.660	377.960	643.180	1119.540	211.660	377.960	643.180	1119.540	0.560	14
244.310	7.000	2.912	2.350	0.187	0.093	1352.000	1481.000	0.551	1.050	2730.740	2.000	1.500	1367.000	1496.000	0.524	0.640	2649.724	0.360	0.640	1880.000	1890.000	211.660	377.960	643.180	1119.540	211.660	377.960	643.180	1119.540	0.560	28
157.320	6.000	2.900	3.000	0.187	0.093	1470.000	1570.000	1.675	1.920	2592.095	2.000	1.000	1330.000	1440.000	0.910	1.720	2621.145	0.360	0.640	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	7
202.660	6.000	2.900	3.000	0.187	0.093	1470.000	1570.000	1.675	1.920	2592.095	2.000	1.000	1330.000	1440.000	0.910	1.720	2621.145	0.360	0.640	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	14
245.490	6.000	2.900	3.000	0.187	0.093	1470.000	1570.000	1.675	1.920	2592.095	2.000	1.000	1330.000	1440.000	0.910	1.720	2621.145	0.360	0.640	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	28
210.000	3.750	2.948	2.850	0.375	0.093	1510.000	1610.000	0.130	3.223	2427.349	1.331	1.000	1286.667	1393.333	0.130	2.530	2642.716	0.360	0.640	1699.300	1716.167	188.000	592.310	607.420	852.200	188.000	592.310	607.420	852.200	0.317	28
204.666	7.500	2.920	2.830	0.187	0.093	1544.300	1685.300	0.470	2.100	2568.619	2.000	1.000	1349.700	1454.300	0.550	2.930	2578.507	0.400	0.600	1810.000	1820.000	215.380	377.860	680.510	1015.450	215.380	377.860	680.510	1015.450	0.570	7
172.546	7.500	2.920	2.830	0.187	0.093	1544.300	1685.300	0.470	2.100	2568.619	2.000	1.000	1349.700	1454.300	0.550	2.930	2578.507	0.400	0.600	1810.000	1820.000	215.380	377.860	680.510	1015.450	215.380	377.860	680.510	1015.450	0.570	14
241.016	7.500	2.920	2.830	0.187	0.093	1544.300	1685.300	0.470	2.100	2568.619	2.000	1.000	1349.700	1454.300	0.550	2.930	2578.507	0.400	0.600	1810.000	1820.000	215.380	377.860	680.510	1015.450	215.380	377.860	680.510	1015.450	0.570	28
162.990	7.500	2.800	3.480	0.375	0.187	1537.000	1740.000	2.668	2.370	2642.360	1.000	0.748	1382.000	1510.000	1.201	1.310	2635.156	0.360	0.640	1862.000	1842.000	180.000	407.500	650.000	950.000	180.000	407.500	650.000	950.000	0.442	7
225.990	7.500	2.800	3.480	0.375	0.187	1537.000	1740.000	2.668	2.370	2642.360	1.000	0.748	1382.000	1510.000	1.201	1.310	2635.156	0.360	0.640	1862.000	1842.000	180.000	407.500	650.000	950.000	180.000	407.500	650.000	950.000	0.442	14
238.460	7.500	2.800	3.480	0.375	0.187	1537.000	1740.000	2.668	2.370	2642.360	1.000	0.748	1382.000	1510.000	1.201	1.310	2635.156	0.360	0.640	1862.000	1842.000	180.000	407.500	650.000	950.000	180.000	407.500	650.000	950.000	0.442	28
183.610	2.450	2.803	2.800	0.187	0.093	1155.200	1817.000	2.720	2.480	2598.000	1.500	1.000	1316.000	1433.000	0.320	2.790	2572.000	0.400	0.600	1938.000	1951.100	218.780	339.520	1035.410	690.270	218.780	339.520	1035.410	690.270	0.644	7
288.020	2.450	2.803	2.800	0.187	0.093	1155.200	1817.000	2.720	2.480	2598.000	1.500	1.000	1316.000	1433.000	0.320	2.790	2572.000	0.400	0.600	1938.000	1951.100	218.780	339.520	1035.410	690.270	218.780	339.520	1035.410	690.270	0.644	28
200.780	2.350	2.803	2.800	0.187	0.093	1155.200	1817.000	2.720	2.480	2598.000	1.500	1.000	1316.000	1433.000	0.320	2.790	2572.000	0.400	0.600	1938.000	1951.100	215.220	346.590	1033.670	689.110	215.220	346.590	1033.670	689.110	0.621	7
297.810	2.350	2.803	2.800	0.187	0.093	1155.200	1817.000	2.720	2.480	2598.000	1.500	1.000	1316.000	1433.000	0.320	2.790	2572.000	0.400	0.600	1938.000	1951.100	215.220	346.590	1033.670	689.110	215.220	346.590	1033.670	689.110	0.621	28
204.060	7.333	2.640	2.760	0.187	0.093	1550.000	1680.000	2.658	1.130	2394.492	1.500	1.000	1710.000	1840.000	2.717	2.000	2296.331	0.260	0.740	1717.000	1728.000	192.100	365.700	481.500	1029.500	192.100	365.700	481.500	1029.500	0.525	7
237.230	7.333	2.640	2.760	0.187	0.093	1550.000	1680.000	2.658	1.130	2394.492	1.500	1.000	1710.000	1840.000	2.717	2.000	2296.331	0.260	0.740	1717.000	1728.000	192.100	365.700	481.500	1029.500	192.100	365.700	481.500	1029.500	0.525	14
274.390	7.333	2.640	2.760	0.187	0.093	1550.000	1680.000	2.658	1.130	2394.492	1.500	1.000	1710.000	1840.000	2.717	2.000	2296.331	0.260	0.740	1717.000	1728.000	192.100	365.700	481.500	1029.500	192.100	365.700	481.500	1029.500	0.525	28
272.810	5.333	2.640	2.760	0.187	0.093	1560.000	1670.000	2.590	1.830	2417.932	1.500	1.000	1230.000	1350.000	3.040	5.150	2392.538	0.360	0.640	1818.000	1854.000	192.200	393.700	456.200	1029.500	192.200	393.700	456.200	1029.500	0.488	7
315.770	5.333	2.640	2.760	0.187	0.093	1560.000	1670.000	2.590	1.830	2417.932	1.500	1.000	1230.000	1350.000	3.040	5.150	2392.538	0.360	0.640	1818.000	1854.000	192.200	393.700	456.200	1029.500	192.200	393.700	456.200	1029.500	0.488	14
274.080	5.333	2.640	2.760	0.187	0.093	1560.000	1670.000	2.590	1.830	2417.932	1.500	1.000	1230.000	1350.000	3.040	5.150	2392.538	0.360	0.640	1818.000	1854.000	192.200	393.700	456.200	1029.500	192.200	393.700	456.200	1029.500	0.488	28
204.918	9.500	2.870	2.980	0.375	0.187	1621.000	1763.000	0.000	3.020	2456.843	0.748	0.748	1324.000	1507.000	0.520	2.410	2475.795	0.360	0.640	1711.000	1784.000	245.230	294.300	812.730	979.550	245.230	294.300	812.730	979.550	0.632	7
272.112	9.500	2.870	2.980	0.375	0.187	1621.000	1763.000	0.000	3.020	2456.843	0.748	0.748	1324.000	1507.000	0.520	2.410	2475.795	0.360	0.640	1711.000	1784.000	245.230	294.300	812.730	979.550	245.230	294.300	812.730	979.550	0.632	14
326.676	9.500	2.870	2.980	0.375	0.187	1621.000	1763.000	0.000	3.020	2456.843	0.748	0.748	1324.000	1507.000	0.520	2.410	2475.795	0.360	0.640	1711.000	1784.000	245.230	294.300	812.730	979.550	245.230	294.300	812.730	979.550	0.632	28
172.546	8.500	2.870	2.834	0.374	0.187	1621.000	1763.000	0.551	2.100	2456.843	1.000	1.000	1324.000	1507.000	0.524	2.930	2475.795	0.400	0.600	1810.000	1820.000	243.390	350.940	762.330	979.550	243.390	350.940	762.330	979.550	0.694	7
204.666	8.500	2.870	2.834	0.374	0.187	1621.000	1763.000	0.551	2.100	2456.843	1.000	1.000	1324.000	1507.000	0.524	2.930	2475.795	0.400	0.600	1810.000	1820.000	243.390	350.940	762.330	979.550	243.390	350.940	762.330	979.550	0.694	14
241.016	8.500	2.870	2.834	0.374	0.187	1621.000	1763.000	0.551	2.100	2456.843	1.000	1.000	1324.000	1507.000	0.524	2.930	2475.795	0.400	0.600	1810.000	1820.000	243.390	350.940	762.330	979.550	243.390	350.940	762.330	979.550	0.694	28
155.810	4.000	2.955	2.300	0.374	0.187	1609.000	1702.000	1.675	2.020	2693.636	2.000	1.500	1388.000	1486.000	0.910	1.320	2736.458	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	7
171.180	4.000	2.955	2.300	0.374	0.187	1609.000	1702.000	1.675	2.020	2693.636	2.000	1.500	1388.000	1486.000	0.910	1.320	2736.458	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	14
211.800	4.000	2.955	2.300	0.374	0.187	1609.000	1702.000	1.675	2.020	2693.636	2.000	1.500	1388.000	1486.000	0.910	1.320	2736.458	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	28
146.810	6.250	2.793	2.598	0.374	0.093	1473.000	1527.000	5.080	1.880	2494.574	1.000	0.748	1373.000	1495.000	2.970	0.710	2674.030	0.450	0.550	1841.000	1844.000	197.661	340.795	742.175	991.330	197.661	340.795	742.175	991.330	0.580	7
172.860	6.250	2.793	2.598	0.374	0.093	1473.000	1527.000	5.080	1.880	2494.574	1.000	0.748	1373.000	1495.000	2.970	0.710	2674.030	0.450	0.550	1841.000	1844.000	197.661	340.795	742.175	991.330	197.661	3				

172.310	7.000	2.693	2.020	0.375	0.093	1543.333	1626.667	2.680	1.110	2402.321	0.750	0.500	1240.000	1373.333	1.100	2.840	2471.947	0.360	0.640	1676.667	1706.667	173.590	309.980	724.890	964.960	173.590	309.980	724.890	964.960	0.560	7
198.410	7.000	2.693	2.020	0.375	0.093	1543.333	1626.667	0.128	1.530	2416.457	0.750	0.500	1240.000	1373.333	0.300	3.180	2484.087	0.360	0.640	1676.667	1706.667	143.364	398.232	434.759	713.786	143.364	398.232	434.759	713.786	0.360	7
144.620	6.900	2.680	3.070	0.375	0.187	1650.000	1560.000	0.125	3.960	2558.611	2.000	1.500	1650.000	1400.000	0.313	3.535	2650.778	0.360	0.640	1910.000	1910.000	167.300	288.440	652.610	1160.190	167.300	288.440	652.610	1160.190	0.580	7
179.000	6.900	2.680	3.070	0.375	0.187	1650.000	1560.000	0.125	3.960	2558.611	2.000	1.500	1650.000	1400.000	0.313	3.535	2650.778	0.360	0.640	1910.000	1910.000	167.300	288.440	652.610	1160.190	167.300	288.440	652.610	1160.190	0.580	14
201.500	6.900	2.680	3.070	0.375	0.187	1650.000	1560.000	0.125	3.960	2558.611	2.000	1.500	1650.000	1400.000	0.313	3.535	2650.778	0.360	0.640	1910.000	1910.000	167.300	288.440	652.610	1160.190	167.300	288.440	652.610	1160.190	0.580	28
227.723	7.000	2.896	2.226	0.187	0.465	1658.500	1730.000	0.310	0.164	2726.304	2.000	1.500	1376.500	1730.000	0.310	0.596	2695.219	0.360	0.640	1970.000	1994.000	193.489	333.601	675.196	1183.536	193.489	333.601	675.196	1183.536	0.580	28
210.000	6.000	2.948	3.203	0.375	0.187	1510.000	1610.000	0.130	3.223	2503.725	0.750	0.750	1286.667	1393.333	0.130	2.530	2437.225	0.360	0.640	1692.000	1692.000	178.110	685.040	547.180	852.200	178.110	685.040	547.180	852.200	0.260	28
208.330	7.500	2.910	3.000	0.187	0.093	1440.000	1520.000	0.130	1.420	2652.302	1.500	0.748	1286.667	1385.000	0.130	1.720	2696.642	0.400	0.600	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	14
251.730	7.500	2.910	3.000	0.187	0.093	1440.000	1520.000	0.130	1.420	2652.302	1.500	0.748	1286.667	1385.000	0.130	1.720	2696.642	0.400	0.600	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	28
138.680	6.000	2.931	2.740	0.374	0.093	1556.400	1699.900	1.990	1.120	2745.114	2.000	1.000	1286.667	1385.000	0.220	0.770	2705.436	0.380	0.620	2002.000	2002.000	185.960	320.621	722.971	1169.535	185.960	320.621	722.971	1169.535	0.580	7
138.680	6.000	2.931	2.740	0.374	0.093	1556.400	1699.900	1.990	1.120	2745.114	2.000	1.000	1568.600	1738.800	0.220	0.770	2705.436	0.380	0.620	1900.000	2002.000	185.960	320.621	722.971	1169.535	185.960	320.621	722.971	1169.535	0.580	7
208.190	6.000	2.931	2.740	0.374	0.093	1556.400	1699.900	1.990	1.120	2745.114	2.000	1.000	1568.600	1738.800	0.220	0.770	2705.436	0.380	0.620	1900.000	2002.000	185.960	320.621	722.971	1169.535	185.960	320.621	722.971	1169.535	0.580	28
155.810	8.000	2.890	2.590	0.374	0.187	1609.000	1702.000	1.675	2.020	2643.375	2.000	1.500	1388.000	1486.000	0.910	1.320	2655.093	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	7
171.180	8.000	2.890	2.590	0.374	0.187	1609.000	1702.000	1.675	2.020	2643.375	2.000	1.500	1388.000	1486.000	0.910	1.320	2655.093	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	14
211.800	8.000	2.890	2.590	0.374	0.187	1609.000	1702.000	1.675	2.020	2643.375	2.000	1.500	1388.000	1486.000	0.910	1.320	2655.093	0.380	0.620	1842.000	1857.000	214.330	369.540	662.410	1064.450	214.330	369.540	662.410	1064.450	0.580	28
146.810	6.250	2.793	2.598	0.374	0.093	1473.000	1527.000	5.080	1.880	2494.574	1.000	0.748	1373.000	1495.000	2.970	0.710	2674.030	0.450	0.550	1841.000	1844.000	197.661	340.795	742.175	991.330	197.661	340.795	742.175	991.330	0.580	7
172.860	6.250	2.793	2.598	0.374	0.093	1473.000	1527.000	5.080	1.880	2494.574	1.000	0.748	1373.000	1495.000	2.970	0.710	2674.030	0.450	0.550	1841.000	1844.000	197.661	340.795	742.175	991.330	197.661	340.795	742.175	991.330	0.580	14
196.700	6.250	2.793	2.598	0.374	0.093	1473.000	1527.000	5.080	1.880	2494.574	1.000	0.748	1373.000	1495.000	2.970	0.710	2674.030	0.450	0.550	1841.000	1844.000	197.661	340.795	742.175	991.330	197.661	340.795	742.175	991.330	0.580	28
210.000	7.500	2.900	3.000	0.187	0.093	1470.000	1570.000	0.130	1.920	2674.173	2.000	1.000	1330.000	1440.000	0.130	1.720	2696.642	0.360	0.640	1850.000	1860.000	207.370	370.310	617.590	1119.210	207.370	370.310	617.590	1119.210	0.560	28
140.780	4.000	3.150	2.800	0.476	0.238	1280.270	1352.270	4.846	5.090	2692.200	1.000	0.750	1416.820	1528.080	1.833	1.870	2731.396	0.502	0.498	2250.000	2250.000	189.000	358.000	855.000	848.000	189.000	358.000	855.000	848.000	0.528	7
150.960	4.000	3.150	2.800	0.476	0.238	1280.270	1352.270	4.846	5.090	2692.200	1.000	0.750	1416.820	1528.080	1.833	1.870	2731.396	0.502	0.498	2250.000	2250.000	189.000	358.000	855.000	848.000	189.000	358.000	855.000	848.000	0.528	14
214.670	4.000	3.150	2.800	0.476	0.238	1280.270	1352.270	4.846	5.090	2692.200	1.000	0.750	1416.820	1528.080	1.833	1.870	2731.396	0.502	0.498	2250.000	2250.000	189.000	358.000	855.000	848.000	189.000	358.000	855.000	848.000	0.528	28
112.300	4.800	3.150	2.800	0.476	0.238	1280.270	1352.270	4.846	5.090	2692.200	1.000	0.750	1416.820	1528.080	1.833	1.870	2731.396	0.491	0.509	2254.000	2254.000	204.000	385.000	817.000	848.000	204.000	385.000	817.000	848.000	0.530	7
150.660	4.800	3.150	2.800	0.476	0.238	1280.270	1352.270	4.846	5.090	2692.200	1.000	0.750	1416.820	1528.080	1.833	1.870	2731.396	0.491	0.509	2254.000	2254.000	204.000	385.000	817.000	848.000	204.000	385.000	817.000	848.000	0.530	14
241.740	4.800	3.150	2.800	0.476	0.238	1280.270	1352.270	4.846	5.090	2692.200	1.000	0.750	1416.820	1528.080	1.833	1.870	2731.396	0.491	0.509	2254.000	2254.000	204.000	385.000	817.000	848.000	204.000	385.000	817.000	848.000	0.530	28
129.650	7.000	3.150	3.090	1.250	0.190	1536.481	1651.717	4.310	1.790	2560.801	1.000	0.750	1639.225	1762.167	0.740	1.420	2732.042	0.420	0.580	2370.610	2337.320	195.000	464.290	644.900	1033.130	185.830	464.290	672.690	1047.800	0.400	7
154.400	7.000	3.150	3.090	1.250	0.190	1536.481	1651.717	4.310	1.790	2560.801	1.000	0.750	1639.225	1762.167	0.740	1.420	2732.042	0.420	0.580	2370.610	2337.320	195.000	464.290	644.900	1033.130	185.830	464.290	672.690	1047.800	0.400	14
215.010	7.000	3.150	3.090	1.250	0.190	1536.481	1651.717	4.310	1.790	2560.801	1.000	0.750	1639.225	1762.167	0.740	1.420	2732.042	0.420	0.580	2370.610	2337.320	195.000	464.290	644.900	1033.130	185.830	464.290	672.690	1047.800	0.400	28
134.000	5.000	2.950	1.750	0.236	0.118	1505.646	1618.569	5.810	4.170	2509.410	1.500	1.000	1315.780	1445.913	1.502	2.790	2661.060	0.403	0.597	2420.000	2362.000	180.000	419.000	693.000	1070.000	182.000	419.000	733.000	1086.000	0.434	7
175.000	5.000	2.950	1.750	0.236	0.118	1505.646	1618.569	5.810	4.170	2509.410	1.500	1.000	1315.780	1445.913	1.502	2.790	2661.060	0.403	0.597	2420.000	2362.000	180.000	419.000	693.000	1070.000	182.000	419.000	733.000	1086.000	0.434	14
200.000	5.000	2.950	1.750	0.236	0.118	1505.646	1618.569	5.810	4.170	2509.410	1.500	1.000	1315.780	1445.913	1.502	2.790	2661.060	0.403	0.597	2420.000	2362.000	180.000	419.000	693.000	1070.000	182.000	419.000	733.000	1086.000	0.434	28
154.000	7.300	2.950	3.000	0.950	0.475	1428.000	1535.100	5.500	4.280	2380.000	1.000	0.750	1542.000	1657.650	1.876	2.040	2570.000	0.427	0.573	2337.000	2337.000	220.000	489.000	695.000	933.000	220.000	489.000	695.000	933.000	0.450	7
214.000	7.300	2.950	3.000	0.950	0.475	1428.000	1535.100	5.500	4.280	2380.000	1.000	0.750	1542.000	1657.650	1.876	2.040	2570.000	0.427	0.573	2337.000	2337.000	220.000	489.000	695.000	933.000	220.000	489.000	695.000	933.000	0.450	14
263.100	7.300	2.950	3.000	0.950	0.475	1428.000	1535.100	5.500	4.280	2380.000	1.000	0.750	1542.000	1657.650	1.876	2.040	2570.000	0.427	0.573	2337.000	2337.000	220.000	489.000	695.000	933.000	220.000	489.000</				

247.154	4.000	2.900	2.950	0.953	0.119	1282.000	1379.000	1.110	4.000	2309.789	2.540	1.905	1267.000	1400.000	1.100	3.907	2703.787	0.483	0.517	1391.000	2068.000	249.000	362.000	742.000	912.000	249.000	362.000	742.000	912.000	0.688	28
156.700	8.750	2.680	2.610	0.476	0.238	1576.630	1752.890	2.300	1.960	2721.175	3.810	2.540	1457.540	1573.060	1.300	3.960	2822.138	0.360	0.640	1773.000	1786.000	229.590	373.815	751.000	1018.610	229.590	373.815	751.000	1018.610	0.614	7
262.070	8.750	2.680	2.610	0.476	0.238	1576.630	1752.890	2.300	1.960	2721.175	3.810	2.540	1457.540	1573.060	1.300	3.960	2822.138	0.360	0.640	1773.000	1786.000	229.590	373.815	751.000	1018.610	229.590	373.815	751.000	1018.610	0.614	28
174.370	8.750	2.680	2.610	0.476	0.238	1576.630	1752.890	2.300	1.960	2721.175	3.810	2.540	1457.540	1573.060	1.300	3.960	2822.138	0.360	0.640	1773.000	1786.000	229.700	404.818	720.000	1018.610	229.700	404.818	720.000	1018.610	0.567	7
299.120	8.750	2.680	2.610	0.476	0.238	1576.630	1752.890	2.300	1.960	2721.175	3.810	2.540	1457.540	1573.060	1.300	3.960	2822.138	0.360	0.640	1773.000	1786.000	229.700	404.818	720.000	1018.610	229.700	404.818	720.000	1018.610	0.567	28
155.800	3.000	3.010	2.893	0.950	0.238	1603.000	1718.000	0.225	1.980	2632.167	1.500	1.000	1459.000	1554.000	0.475	2.217	2603.798	0.460	0.540	1893.000	1897.000	197.940	353.470	828.580	955.300	197.940	353.470	828.580	955.300	0.560	7
193.020	3.000	3.010	2.893	0.950	0.238	1603.000	1718.000	0.225	1.980	2632.167	1.500	1.000	1459.000	1554.000	0.475	2.217	2603.798	0.460	0.540	1893.000	1897.000	197.940	353.470	828.580	955.300	197.940	353.470	828.580	955.300	0.560	14
237.590	3.000	3.010	2.893	0.950	0.238	1603.000	1718.000	0.225	1.980	2632.167	1.500	1.000	1459.000	1554.000	0.475	2.217	2603.798	0.460	0.540	1893.000	1897.000	197.940	353.470	828.580	955.300	197.940	353.470	828.580	955.300	0.560	28
138.810	6.900	2.750	2.365	0.475	0.118	1454.000	1601.000	2.860	1.960	2327.671	1.500	1.000	1320.000	1438.000	1.030	2.740	2505.854	0.460	0.540	1938.000	1951.000	164.399	283.446	847.921	993.741	164.399	283.446	847.921	993.741	0.580	7
178.830	6.900	2.750	2.365	0.475	0.118	1454.000	1601.000	2.860	1.960	2327.671	1.500	1.000	1320.000	1438.000	1.030	2.740	2505.854	0.460	0.540	1938.000	1951.000	164.399	283.446	847.921	993.741	164.399	283.446	847.921	993.741	0.580	14
215.450	6.900	2.750	2.365	0.475	0.118	1454.000	1601.000	2.860	1.960	2327.671	1.500	1.000	1320.000	1438.000	1.030	2.740	2505.854	0.460	0.540	1938.000	1951.000	164.399	283.446	847.921	993.741	164.399	283.446	847.921	993.741	0.580	28
139.020	6.000	2.887	2.220	0.950	0.119	1565.000	1660.000	0.434	0.436	2757.874	1.500	0.750	1388.000	1481.000	1.674	1.702	2799.211	0.460	0.540	1955.000	1961.000	213.190	367.560	835.170	998.230	213.190	367.560	835.170	998.230	0.580	7
186.610	6.000	2.887	2.220	0.950	0.119	1565.000	1660.000	0.434	0.436	2757.874	1.500	0.750	1388.000	1481.000	1.674	1.702	2799.211	0.460	0.540	1955.000	1961.000	213.190	367.560	835.170	998.230	213.190	367.560	835.170	998.230	0.580	14
235.560	6.000	2.887	2.220	0.950	0.119	1565.000	1660.000	0.434	0.436	2757.874	1.500	0.750	1388.000	1481.000	1.674	1.702	2799.211	0.460	0.540	1955.000	1961.000	213.190	367.560	835.170	998.230	213.190	367.560	835.170	998.230	0.580	28
192.050	6.000	2.887	2.220	0.950	0.119	1565.000	1660.000	0.434	0.436	2757.874	1.500	0.750	1388.000	1481.000	1.674	1.702	2799.211	0.460	0.540	1955.000	1961.000	204.370	393.020	835.170	998.230	204.370	393.020	835.170	998.230	0.520	7
253.570	6.000	2.887	2.220	0.950	0.119	1565.000	1660.000	0.434	0.436	2757.874	1.500	0.750	1388.000	1481.000	1.674	1.702	2799.211	0.460	0.540	1955.000	1961.000	204.370	393.020	835.170	998.230	204.370	393.020	835.170	998.230	0.520	14
288.920	6.000	2.887	2.220	0.950	0.119	1565.000	1660.000	0.434	0.436	2757.874	1.500	0.750	1388.000	1481.000	1.674	1.702	2799.211	0.460	0.540	1955.000	1961.000	204.370	393.020	835.170	998.230	204.370	393.020	835.170	998.230	0.520	28
137.660	6.000	2.887	2.140	0.476	0.119	1462.000	1539.000	0.922	0.903	2747.035	1.500	0.750	1365.000	1472.000	1.679	1.708	2650.528	0.410	0.590	1929.000	1938.000	203.830	351.430	758.220	1056.090	203.830	351.430	758.220	1056.090	0.580	7
183.210	6.000	2.887	2.140	0.476	0.119	1462.000	1539.000	0.922	0.903	2747.035	1.500	0.750	1365.000	1472.000	1.679	1.708	2650.528	0.410	0.590	1929.000	1938.000	203.830	351.430	758.220	1056.090	203.830	351.430	758.220	1056.090	0.580	14
232.160	6.000	2.887	2.140	0.476	0.119	1462.000	1539.000	0.922	0.903	2747.035	1.500	0.750	1365.000	1472.000	1.679	1.708	2650.528	0.410	0.590	1929.000	1938.000	203.830	351.430	758.220	1056.090	203.830	351.430	758.220	1056.090	0.580	28
189.670	6.000	2.887	2.140	0.476	0.119	1462.000	1539.000	0.922	0.903	2747.035	1.500	0.750	1365.000	1472.000	1.679	1.708	2650.528	0.410	0.590	1929.000	1938.000	195.400	375.760	758.220	1056.090	195.400	375.760	758.220	1056.090	0.520	7
253.230	6.000	2.887	2.140	0.476	0.119	1462.000	1539.000	0.922	0.903	2747.035	1.500	0.750	1365.000	1472.000	1.679	1.708	2650.528	0.410	0.590	1929.000	1938.000	195.400	375.760	758.220	1056.090	195.400	375.760	758.220	1056.090	0.520	14
288.240	6.000	2.887	2.140	0.476	0.119	1462.000	1539.000	0.922	0.903	2747.035	1.500	0.750	1365.000	1472.000	1.679	1.708	2650.528	0.410	0.590	1929.000	1938.000	195.400	375.760	758.220	1056.090	195.400	375.760	758.220	1056.090	0.520	28
146.000	7.000	3.161	2.890	0.950	0.236	1534.000	1575.000	0.030	2.031	2653.996	1.000	0.750	1230.000	1320.000	0.090	1.953	2751.561	0.360	0.640	1742.000	1801.000	260.726	449.527	569.599	1053.889	260.726	449.527	569.599	1053.889	0.580	7
179.950	7.000	3.161	2.890	0.950	0.236	1534.000	1575.000	0.030	2.031	2653.996	1.000	0.750	1230.000	1320.000	0.090	1.953	2751.561	0.360	0.640	1742.000	1801.000	260.726	449.527	569.599	1053.889	260.726	449.527	569.599	1053.889	0.580	14
203.720	7.000	3.161	2.890	0.950	0.236	1534.000	1575.000	0.030	2.031	2653.996	1.000	0.750	1230.000	1320.000	0.090	1.953	2751.561	0.360	0.640	1742.000	1801.000	260.726	449.527	569.599	1053.889	260.726	449.527	569.599	1053.889	0.580	28
156.000	10.000	2.970	2.810	0.950	0.236	1624.000	1749.000	2.500	1.850	2613.994	1.500	1.000	1306.000	1472.000	1.520	2.500	2540.323	0.460	0.540	1971.000	1970.000	165.120	311.546	868.208	1003.725	165.120	311.546	868.208	1003.725	0.570	7
195.000	10.000	2.970	2.810	0.950	0.236	1624.000	1749.000	2.500	1.850	2613.994	1.500	1.000	1306.000	1472.000	1.520	2.500	2540.323	0.460	0.540	1971.000	1970.000	165.120	311.546	868.208	1003.725	165.120	311.546	868.208	1003.725	0.570	14
238.000	10.000	2.970	2.810	0.950	0.236	1624.000	1749.000	2.500	1.850	2613.994	1.500	1.000	1306.000	1472.000	1.520	2.500	2540.323	0.460	0.540	1971.000	1970.000	165.120	311.546	868.208	1003.725	165.120	311.546	868.208	1003.725	0.570	28
156.470	6.500	2.942	2.802	0.950	0.236	1618.000	1749.000	2.590	1.940	2613.994	1.500	1.000	1365.000	1480.000	0.680	2.240	2548.978	0.460	0.540	1971.000	1970.000	170.167	298.538	866.408	1005.057	170.167	298.538	866.408	1005.057	0.570	7
192.470	6.500	2.942	2.802	0.950	0.236	1618.000	1749.000	2.590	1.940	2613.994	1.500	1.000	1365.000	1480.000	0.680	2.240	2548.978	0.460	0.540	1971.000	1970.000	170.167	298.538	866.408	1005.057	170.167	298.538	866.408	1005.057	0.570	14
230.400	6.500	2.942	2.802	0.950	0.236	1618.000	1749.000	2.590	1.940	2613.994	1.500	1.000	1365.000	1480.000	0.680	2.240	2548.978	0.460	0.540	1971.000	1970.000	170.167	298.538	866.408	1005.057	170.167	298.538	866.408	1005.057	0.570	28
182.570	7.000	2.942	2.802	0.950	0.236	1618.000	1749.000	2.590	1.940	2613.994	1.500	1.000	1365.000	1480.000	0.680	2.240	2548.978	0.460	0.540	1971.000	1970.000	165.501	312.265	866.408	1005.057	165.501	312.265	866.408	1005.057	0.530	7
229.370	7.000	2.942	2.802	0.950	0.236	1618.000	1749.000	2.590	1.940	2613.994	1.500	1.000	1365.000	1480.000	0.680	2.240	2548.978	0.460	0.540	1971.000	1970.000	165.501	312.265	866.408	1005.057	165.501	31				

Anexo 8: Datos para aplicación del modelo

N° Fuente	Titulo	Universidad	Autor	Link	f'c de laboratorio	Asent_hormig on (cm)	Dens_cemento (gr/cm³)	AGREGADO FINO							AGREGADO GRUESO							MEZCLA DE AGREGADOS		CANTIDAD CORREGIDA					a/c	ln(Edad)
								MF_af	TM_af (cm)	TNM_af (cm)	DAS_af (kg/m³)	DAC_af (kg/m³)	Porc_hum_af %	Porc_abs_af %	DA_af (kg/m³)	TM_ag in	TNM_ag in	DAS_ag (kg/m³)	DAC_ag (kg/m³)	Porc_hum_ag %	Porc_abs_ag %	DA_ag (kg/m³)	Porc_opt_af	DO_mezcla (kg/m³)	Agua_corr (kg)	Cemento_corr (kg)	Arena_corr (kg)	Grava_corr (kg)		
1	Análisis de la resistencia a compresión del concreto expuesto a fuego, elaborado a base de talco industrial como remplazo parcial del agregado fino	Universidad Técnica de Ambato	Daniel Eliecer Moreno de la Cruz	https://repositorio.uta.edu.ec/server/api/core/bitstreams/1a7a31a3-15aa-4de1-9683-f1d038233831/content	208.390	7.500	2.800	2.900	0.950	0.476	1479.000	1596.000	2.450	1.260	2315.777	1.500	1.000	1398.000	1547.000	0.340	2.250	2572.741	0.360	1859.000	225.550	402.760	734.030	998.890	0.580	3.332
2	Análisis de la influencia del tipo de agregados pétreos en las propiedades fiso-mecánicas del hormigón producido con la aplicación del súper e hiper-plastificantes	Universidad Católica de Cuenca	Edwin Vinicio Salinas Tenesaca	https://dspace.ucaue.edu.ec/server/api/core/bitstreams/604da41c-5873-4a2a-b6ae-e00838b686db/content	210.410	7.600	3.000	3.050	0.952	0.238	1500.000	1650.000	6.150	0.900	2715.100	1.500	0.750	1520.000	1669.760	1.180	1.520	2769.200	0.456	1660.749	166.410	366.070	850.210	1013.680	0.560	3.332
3	Evaluación de las propiedades físicas y mecánicas de un hormigón reforzado con fibras de acero en la ciudad de Azogues, provincia del Cañar	Universidad Católica de Cuenca	Jaime Luciano Rojas Cruz	https://dspace.ucaue.edu.ec/server/api/core/bitstreams/c700be3-1967-476d-a828-e05232615953/content	217.320	9.000	3.140	2.660	0.950	0.240	1442.370	1580.340	1.420	1.420	2679.060	1.000	1.000	1311.440	1427.860	1.150	1.150	2922.730	0.476	1500.440	195.000	354.550	882.225	972.340	0.550	3.332
4	eterminación del módulo de elasticidad en hormigones estructurales de 21 y 28 Mpa utilizando agregados de la cantera Agresa	Universidad Estatal del Sur de Manabí	Elvis Patricio Chele	https://repositorio.unesum.edu.ec/bitstream/53000/2011/1/UNESUM-ECUADOR-ING.CIVIL-2019-94.pdf	240.041	7.000	2.930	3.100	0.950	0.236	1512.000	1688.333	5.843	3.890	2715.000	1.000	0.750	1432.000	1527.333	3.503	2.016	2769.200	0.427	1596.080	200.000	363.640	694.890	929.840	0.550	3.332
5	Análisis comparativo de la resistencia a la compresión del hormigón con adición de virutas metálicas y un hormigón con materiales tradicionales	Universidad Técnica de Ambato	Edwin Manuel Acosta Villacres	https://repositorio.uta.edu.ec/server/api/core/bitstreams/d0b94401-087b-401b-895d-8dbb6a9fa292/content	251.948	6.500	2.852	2.360	0.950	0.238	1461.000	1599.000	2.270	1.340	2693.956	1.000	1.000	1327.000	1466.000	1.540	2.520	2641.899	0.468	1971.000	171.386	300.677	875.844	994.002	0.570	3.332
6	Módulo de Elasticidad del hormigón en base a la compresión de (f'c=21,28) Mpa, con materiales de la cantera Megarok de la provincia de Manabí	Universidad Estatal del Sur de Manabí	Byron Baque Campozano, Boris Ricardo Pico Ponce	https://repositorio.unesum.edu.ec/bitstream/53000/2012/1/UNESUM-ECUADOR-ING.CIVIL-2019-95.pdf	257.050	6.000	2.931	2.510	0.475	0.236	1627.000	1524.000	12.360	3.870	2614.192	1.000	0.750	1439.000	1558.000	4.340	4.660	2651.504	0.401	1544.366	200.000	362.320	676.060	1011.140	0.550	3.332
7	Análisis comparativo de la resistencia a la compresión del hormigón con adición de virutas metálicas y un hormigón con materiales tradicionales	Universidad Técnica de Ambato	Edwin Manuel Acosta Villacres	https://repositorio.uta.edu.ec/server/api/core/bitstreams/d0b94401-087b-401b-895d-8dbb6a9fa292/content	271.030	6.500	2.852	2.360	0.950	0.238	1461.000	1599.000	2.270	1.340	2693.956	1.000	1.000	1327.000	1466.000	1.540	2.520	2641.899	0.460	1971.000	166.597	314.334	875.844	994.002	0.530	3.332
8	Los agregados de las minas ubicadas junto a la vía Puyo-Madre Tierra Provincia de Pastaza y su incidencia en la resistencia del hormigón	Universidad Técnica de Ambato	Jazmina Daniela Tamayo Ledesma	https://repositorio.uta.edu.ec/items/5bd1b7b5-59f5-4739-867c-3824144ac543	281.000	8.000	3.025	3.100	0.475	0.236	1410.000	1570.000	1.030	1.030	1410.000	2.000	1.000	1450.000	1670.000	2.600	0.640	1450.000	0.234	1980.000	174.651	311.878	447.215	1460.096	0.560	3.332
9	La resistencia a la compresión del hormigón y su influencia en el módulo de elasticidad estático en el cantón Ambato, Provincia de Tungurahua	Universidad Técnica de Ambato	Jorge Luis Sánchez García	https://repositorio.uta.edu.ec/server/api/core/bitstreams/5edb7b50-7962-4bdb-bac2-65aeffe61cdc/content	283.450	6.000	3.048	2.500	0.950	0.475	1306.000	1531.000	1.200	0.610	2522.937	1.500	1.000	1395.000	1551.000	5.500	3.040	2810.815	0.330	1799.000	204.146	364.547	543.909	1122.763	0.560	3.332
10	eterminación del módulo de elasticidad en hormigones estructurales de 21 y 28 Mpa utilizando agregados de la cantera Agresa	Universidad Estatal del Sur de Manabí	Elvis Patricio Chele	https://repositorio.unesum.edu.ec/bitstream/53000/2011/1/UNESUM-ECUADOR-ING.CIVIL-2019-94.pdf	303.468	7.000	2.930	3.100	0.950	0.236	1512.000	1688.333	5.843	3.890	2715.000	1.000	0.750	1432.000	1527.333	3.503	2.016	2769.200	0.409	2201.200	200.000	429.180	642.180	929.840	0.470	3.332
11	Hormigón con agregados reciclados de demolición de estructuras de hormigón	Universidad Católica Santiago de Guayaquil	Bayron Gustavo Cadme Cárdenas	http://repositorio.ucsug.edu.ec/handle/3317/1308	325.110	10.000	3.150	2.920	0.475	0.236	1487.000	1636.000	1.630	1.630	2617.000	1.000	0.750	1561.000	1741.000	1.940	1.940	2657.462	0.353	1785.000	201.710	470.460	593.630	1086.160	0.429	3.332
12	Hormigón con agregados reciclados de demolición de estructuras de hormigón	Universidad Católica Santiago de Guayaquil	Bayron Gustavo Cadme Cárdenas	http://repositorio.ucsug.edu.ec/handle/3317/1308	329.920	10.000	3.150	2.920	0.475	0.236	1487.000	1636.000	1.630	1.630	2617.000	1.000	0.750	1561.000	1741.000	1.940	1.940	2657.462	0.366	1800.000	201.710	430.480	626.540	1086.160	0.469	3.332

Anexo 9: Predicción para $f'_c=210 \text{ kg/cm}^2$ muestra 1



UNIVERSIDAD TÉCNICA DE AMBATO

FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA

INGENIERÍA CIVIL



TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"

MODELO LASSO-3 ($f_c=210 \text{ kg/cm}^2$)

MUESTRA 1

Fecha:

17 de mayo de 2026

Elaborado por:

Karen Alexandra Mosquera Merchán

Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.

Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
Asent_hormigon	cm	7.500	7.047	2.923	0.155	2.443	0.379
Dens_cemento	gr/cm ³	2.800	2.879	0.130	-0.608	-3.657	2.225
MF_af	adimensional	2.900	2.705	0.364	0.535	-2.804	-1.502
TM_af	cm	0.950	0.512	0.296	1.479	-4.211	-6.227
TNM_af	cm	0.476	0.196	0.149	1.871	-2.034	-3.806
DAS_af	kg/m ³	1479.000	1517.676	124.096	-0.312	-5.423	1.690
DAC_af	kg/m ³	1596.000	1646.206	120.781	-0.416	3.499	-1.454
Porc_hum_af	%	2.450	2.694	2.181	-0.112	-1.06	0.118
Porc_abs_af	%	1.260	2.322	1.571	-0.676	-9.558	6.463
DA_af	kg/m ³	2315.777	2578.694	120.327	-2.185	1.309	-2.860
TM_ag	in	1.500	1.478	0.552	0.040	-6.526	-0.263
TNM_ag	in	1.000	1.007	0.383	-0.017	3.373	-0.058
DAS_ag	kg/m ³	1398.000	1419.037	126.925	-0.166	0.351	-0.058
DAC_ag	kg/m ³	1547.000	1535.439	132.295	0.087	7.057	0.617
Porc_hum_ag	%	0.340	1.666	2.407	-0.551	-2.416	1.331
Porc_abs_ag	%	2.250	2.384	1.633	-0.082	19.032	-1.566
DA_ag	kg/m ³	2572.741	2632.632	120.982	-0.495	-6.852	3.392
Porc_opt_af	(0 a 1)	0.360	0.413	0.060	-0.887	-0.657	0.583
DO_mezcla	kg/m ³	1859.000	1948.160	206.973	-0.431	-4.769	2.054
Agua_corr	kg	225.550	200.306	25.732	0.981	25.165	24.687
Cemento_corr	kg	402.760	366.061	67.484	0.544	-24.829	-13.503
Arena_corr	kg	734.030	734.582	131.198	-0.004	12.951	-0.054
Grava_corr	kg	998.890	1008.736	119.555	-0.082	1.204	-0.099
a/c	adimensional	0.580	0.555	0.073	0.346	-38.932	-13.489
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'_c real de laboratorio (kg/cm ²)							208.390
Valor de f'_c predicho (kg/cm ²)							242.664
Error (kg/cm ²)							34.274
Error %							16.447

Anexo 10: Predicción para $f'c=210 \text{ kg/cm}^2$ muestra 2

UNIVERSIDAD TÉCNICA DE AMBATO		FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA INGENIERÍA CIVIL					
TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"							
MODELO LASSO-3 ($f'_c=210 \text{ kg/cm}^2$) MUESTRA 2							
Fecha:	17 de mayo de 2026						
Elaborado por:	Karen Alexandra Mosquera Merchán						
Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.							
Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
Asent_hormigon	cm	9.000	7.047	2.923	0.668	2.443	1.632
Dens_cemento	gr/cm³	3.140	2.879	0.130	2.014	-3.657	-7.364
MF_af	adimensional	2.660	2.705	0.364	-0.123	-2.804	0.345
TM_af	cm	0.950	0.512	0.296	1.479	-4.211	-6.227
TNM_af	cm	0.240	0.196	0.149	0.291	-2.034	-0.593
DAS_af	kg/m³	1442.370	1517.676	124.096	-0.607	-5.423	3.291
DAC_af	kg/m³	1580.340	1646.206	120.781	-0.545	3.499	-1.908
Porc_hum_af	%	1.420	2.694	2.181	-0.584	-1.06	0.619
Porc_abs_af	%	1.420	2.322	1.571	-0.574	-9.558	5.489
DA_af	kg/m³	2679.060	2578.694	120.327	0.834	1.309	1.092
TM_ag	in	1.000	1.478	0.552	-0.866	-6.526	5.653
TNM_ag	in	1.000	1.007	0.383	-0.017	3.373	-0.058
DAS_ag	kg/m³	1311.440	1419.037	126.925	-0.848	0.351	-0.298
DAC_ag	kg/m³	1427.860	1535.439	132.295	-0.813	7.057	-5.739
Porc_hum_ag	%	1.150	1.666	2.407	-0.214	-2.416	0.518
Porc_abs_ag	%	1.150	2.384	1.633	-0.756	19.032	-14.387
DA_ag	kg/m³	2922.730	2632.632	120.982	2.398	-6.852	-16.430
Porc_opt_af	(0 a 1)	0.476	0.413	0.060	1.045	-0.657	-0.687
DOmezcla	kg/m³	1500.440	1948.160	206.973	-2.163	-4.769	10.316
Agua_corr	kg	195.000	200.306	25.732	-0.206	25.165	-5.189
Cemento_corr	kg	354.550	366.061	67.484	-0.171	-24.829	4.235
Arena_corr	kg	882.225	734.582	131.198	1.125	12.951	14.574
Grava_corr	kg	972.340	1008.736	119.555	-0.304	1.204	-0.367
a/c	adimensional	0.550	0.555	0.073	-0.063	-38.932	2.457
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'_c real de laboratorio (kg/cm^2)							217.320
Valor de f'_c predicho (kg/cm^2)							235.041
Error (kg/cm^2)							17.721
Error %							8.154

Anexo 11: Predicción para $f'_c=210 \text{ kg/cm}^2$ muestra 3

UNIVERSIDAD TÉCNICA DE AMBATO

FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA

INGENIERÍA CIVIL

TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"

MODELO LASSO-3 ($f'_c=210 \text{ kg/cm}^2$)

MUESTRA 3

Fecha:

17 de mayo de 2026

Elaborado por:

Karen Alexandra Mosquera Merchán

Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.

Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
Asent_hormigon	cm	7.600	7.047	2.923	0.189	2.443	0.462
Dens_cemento	gr/cm ³	3.000	2.879	0.130	0.934	-3.657	-3.416
MF_af	adimensional	3.050	2.705	0.364	0.947	-2.804	-2.656
TM_af	cm	0.952	0.512	0.296	1.485	-4.211	-6.255
TNM_af	cm	0.238	0.196	0.149	0.278	-2.034	-0.566
DAS_af	kg/m ³	1500.000	1517.676	124.096	-0.142	-5.423	0.772
DAC_af	kg/m ³	1650.000	1646.206	120.781	0.031	3.499	0.110
Porc_hum_af	%	6.150	2.694	2.181	1.585	-1.06	-1.680
Porc_abs_af	%	0.900	2.322	1.571	-0.905	-9.558	8.653
DA_af	kg/m ³	2715.100	2578.694	120.327	1.134	1.309	1.484
TM_ag	in	1.500	1.478	0.552	0.040	-6.526	-0.263
TNM_ag	in	0.750	1.007	0.383	-0.670	3.373	-2.259
DAS_ag	kg/m ³	1520.000	1419.037	126.925	0.795	0.351	0.279
DAC_ag	kg/m ³	1669.760	1535.439	132.295	1.015	7.057	7.165
Porc_hum_ag	%	1.180	1.666	2.407	-0.202	-2.416	0.487
Porc_abs_ag	%	1.520	2.384	1.633	-0.529	19.032	-10.074
DA_ag	kg/m ³	2769.200	2632.632	120.982	1.129	-6.852	-7.735
Porc_opt_af	(0 a 1)	0.456	0.413	0.060	0.712	-0.657	-0.468
DOmezcla	kg/m ³	1660.749	1948.160	206.973	-1.389	-4.769	6.622
Agua_corr	kg	166.410	200.306	25.732	-1.317	25.165	-33.149
Cemento_corr	kg	366.070	366.061	67.484	0.000	-24.829	-0.003
Arena_corr	kg	850.210	734.582	131.198	0.881	12.951	11.414
Grava_corr	kg	1013.680	1008.736	119.555	0.041	1.204	0.050
a/c	adimensional	0.560	0.555	0.073	0.073	-38.932	-2.858
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'_c real de laboratorio (kg/cm ²)							210.410
Valor de f'_c predicho (kg/cm ²)							210.184
Error (kg/cm ²)							0.226
Error %							0.107

Anexo 12: Predicción para $f'_c=240 \text{ kg/cm}^2$ muestra 1


UNIVERSIDAD TÉCNICA DE AMBATO
FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA
INGENIERÍA CIVIL


TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"							
MODELO LASSO-3 ($f_c=240\text{ kg/cm}^2$) MUESTRA I							
Fecha:	17 de mayo de 2026						
Elaborado por:	Karen Alexandra Mosquera Merchán						
Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.							
Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coeficiente β	Contribución
Asent_hormigon	cm	7.000	7.047	2.923	-0.016	2.443	-0.039
Dens_cemento	gr/cm³	2.930	2.879	0.130	0.394	-3.657	-1.441
MF_af	adimensional	3.100	2.705	0.364	1.084	-2.804	-3.040
TM_af	cm	0.950	0.512	0.296	1.479	-4.211	-6.227
TNM_af	cm	0.236	0.196	0.149	0.265	-2.034	-0.538
DAS_af	kg/m³	1512.000	1517.676	124.096	-0.046	-5.423	0.248
DAC_af	kg/m³	1688.333	1646.206	120.781	0.349	3.499	1.220
Porc_hum_af	%	5.843	2.694	2.181	1.444	-1.06	-1.530
Porc_abs_af	%	3.890	2.322	1.571	0.998	-9.558	-9.540
DA_af	kg/m³	2715.000	2578.694	120.327	1.133	1.309	1.483
TM_ag	in	1.000	1.478	0.552	-0.866	-6.526	5.653
TNM_ag	in	0.750	1.007	0.383	-0.670	3.373	-2.259
DAS_ag	kg/m³	1432.000	1419.037	126.925	0.102	0.351	0.036
DAC_ag	kg/m³	1527.333	1535.439	132.295	-0.061	7.057	-0.432
Porc_hum_ag	%	3.503	1.666	2.407	0.763	-2.416	-1.845
Porc_abs_ag	%	2.016	2.384	1.633	-0.226	19.032	-4.293
DA_ag	kg/m³	2769.200	2632.632	120.982	1.129	-6.852	-7.735
Porc_opt_af	(0 a 1)	0.427	0.413	0.060	0.229	-0.657	-0.150
DO_mezcla	kg/m³	1596.080	1948.160	206.973	-1.701	-4.769	8.113
Agua_corr	kg	200.000	200.306	25.732	-0.012	25.165	-0.300
Cemento_corr	kg	363.640	366.061	67.484	-0.036	-24.829	0.891
Arena_corr	kg	694.890	734.582	131.198	-0.303	12.951	-3.918
Grava_corr	kg	929.840	1008.736	119.555	-0.660	1.204	-0.795
a/c	adimensional	0.550	0.555	0.073	-0.063	-38.932	2.457
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'c real de laboratorio (kg/cm^2)							240.041
Valor de f'c predicho (kg/cm^2)							220.083
Error (kg/cm^2)							19.958
Error %							8.314

Anexo 13: Predicción para $f'_c=240 \text{ kg/cm}^2$ muestra 2

UNIVERSIDAD TÉCNICA DE AMBATO
FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA
INGENIERÍA CIVIL

TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"

MODELO LASSO-3 ($f'_c=240 \text{ kg/cm}^2$)

MUESTRA 2

Fecha:	17 de mayo de 2026
Elaborado por:	Karen Alexandra Mosquera Merchán

Nota: Ingresar el valor de $\ln(\text{Edad})$ debe ingresarse ya transformado.

Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
Asent_hormigon	cm	6.500	7.047	2.923	-0.187	2.443	-0.457
Dens_cemento	gr/cm ³	2.852	2.879	0.130	-0.207	-3.657	0.758
MF_af	adimensional	2.360	2.705	0.364	-0.946	-2.804	2.653
TM_af	cm	0.950	0.512	0.296	1.479	-4.211	-6.227
TNM_af	cm	0.238	0.196	0.149	0.278	-2.034	-0.566
DAS_af	kg/m ³	1461.000	1517.676	124.096	-0.457	-5.423	2.477
DAC_af	kg/m ³	1599.000	1646.206	120.781	-0.391	3.499	-1.368
Porc_hum_af	%	2.270	2.694	2.181	-0.194	-1.06	0.206
Porc_abs_af	%	1.340	2.322	1.571	-0.625	-9.558	5.976
DA_af	kg/m ³	2693.956	2578.694	120.327	0.958	1.309	1.254
TM_ag	in	1.000	1.478	0.552	-0.866	-6.526	5.653
TNM_ag	in	1.000	1.007	0.383	-0.017	3.373	-0.058
DAS_ag	kg/m ³	1327.000	1419.037	126.925	-0.725	0.351	-0.255
DAC_ag	kg/m ³	1466.000	1535.439	132.295	-0.525	7.057	-3.704
Porc_hum_ag	%	1.540	1.666	2.407	-0.052	-2.416	0.126
Porc_abs_ag	%	2.520	2.384	1.633	0.083	19.032	1.581
DA_ag	kg/m ³	2641.899	2632.632	120.982	0.077	-6.852	-0.525
Porc_opt_af	(0 a 1)	0.468	0.413	0.060	0.912	-0.657	-0.599
DO_mezcla	kg/m ³	1971.000	1948.160	206.973	0.110	-4.769	-0.526
Agua_corr	kg	171.386	200.306	25.732	-1.124	25.165	-28.283
Cemento_corr	kg	300.677	366.061	67.484	-0.969	-24.829	24.056
Arena_corr	kg	875.844	734.582	131.198	1.077	12.951	13.945
Grava_corr	kg	994.002	1008.736	119.555	-0.123	1.204	-0.148
a/c	adimensional	0.570	0.555	0.073	0.210	-38.932	-8.174
$\ln(\text{Edad})$	adimensional	3.332	2.636	0.578	1.205	34.221	41.222

Intercepto del modelo (β_0)

202.843

Valor de f'_c real de laboratorio (kg/cm^2)

251.948

Valor de f'_c predicho (kg/cm^2)

251.861

Error (kg/cm^2)

0.087

Error %

0.035

Anexo 14: Predicción para $f_c=240 \text{ kg/cm}^2$ muestra 3

UNIVERSIDAD TÉCNICA DE AMBATO
FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA
INGENIERÍA CIVIL

TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"

MODELO LASSO-3 ($f'_c=240 \text{ kg/cm}^2$)

MUESTRA 3

Fecha:	17 de mayo de 2026
Elaborado por:	Karen Alexandra Mosquera Merchán

Nota: Ingresar el valor de $\ln(\text{Edad})$ debe ingresarse ya transformado.

Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
t_hormigon	cm	6.000	7.047	2.923	-0.358	2.443	-0.875
s_cemento	gr/cm ³	2.931	2.879	0.130	0.402	-3.657	-1.470
MF_af	adimensional	2.510	2.705	0.364	-0.535	-2.804	1.499
TM_af	cm	0.475	0.512	0.296	-0.126	-4.211	0.529
INM_af	cm	0.236	0.196	0.149	0.265	-2.034	-0.538
DAS_af	kg/m ³	1627.000	1517.676	124.096	0.881	-5.423	-4.777
DAC_af	kg/m ³	1524.000	1646.206	120.781	-1.012	3.499	-3.540
rc_hum_af	%	12.360	2.694	2.181	4.431	-1.06	-4.697
rc_abs_af	%	3.870	2.322	1.571	0.985	-9.558	-9.418
DA_af	kg/m ³	2614.192	2578.694	120.327	0.295	1.309	0.386
TM_ag	in	1.000	1.478	0.552	-0.866	-6.526	5.653
INM_ag	in	0.750	1.007	0.383	-0.670	3.373	-2.259
DAS_ag	kg/m ³	1439.000	1419.037	126.925	0.157	0.351	0.055
DAC_ag	kg/m ³	1558.000	1535.439	132.295	0.171	7.057	1.203
rc_hum_ag	%	4.340	1.666	2.407	1.111	-2.416	-2.685
rc_abs_ag	%	4.660	2.384	1.633	1.394	19.032	26.525
DA_ag	kg/m ³	2651.504	2632.632	120.982	0.156	-6.852	-1.069
rc_opt_af	(0 a 1)	0.401	0.413	0.060	-0.204	-0.657	0.134
D_mezcla	kg/m ³	1544.366	1948.160	206.973	-1.951	-4.769	9.304
agua_corr	kg	200.000	200.306	25.732	-0.012	25.165	-0.300
cemento_corr	kg	362.320	366.061	67.484	-0.055	-24.829	1.376
arena_corr	kg	676.060	734.582	131.198	-0.446	12.951	-5.777
grava_corr	kg	1011.140	1008.736	119.555	0.020	1.204	0.024
a/c	adimensional	0.550	0.555	0.073	-0.063	-38.932	2.457
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222

Intercepto del modelo (β_0)

202.843

Valor de f'_c real de laboratorio (kg/cm²)

257.050

Valor de f'_c predicho (kg/cm²)

255.807

Error (kg/cm²)

1.243

Error %

0.484

Anexo 15: Predicción para $f'c=280 \text{ kg/cm}^2$ muestra 1

		UNIVERSIDAD TÉCNICA DE AMBATO FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA INGENIERÍA CIVIL					
TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"							
MODELO LASSO-3 ($f'c=280\text{ kg/cm}^2$)							
MUESTRA 1							
Fecha:	17 de mayo de 2026						
Elaborado por:	Karen Alexandra Mosquera Merchán						
Nota: Ingresar el valor de $\ln(\text{Edad})$ debe ingresarse ya transformado.							
Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
Asent_hormigon	cm	6.500	7.047	2.923	-0.187	2.443	-0.457
Dens_cemento	gr/cm ³	2.852	2.879	0.130	-0.207	-3.657	0.758
MF_af	adimensional	2.360	2.705	0.364	-0.946	-2.804	2.653
TM_af	cm	0.950	0.512	0.296	1.479	-4.211	-6.227
TNM_af	cm	0.238	0.196	0.149	0.278	-2.034	-0.566
DAS_af	kg/m ³	1461.000	1517.676	124.096	-0.457	-5.423	2.477
DAC_af	kg/m ³	1599.000	1646.206	120.781	-0.391	3.499	-1.368
Porc_hum_af	%	2.270	2.694	2.181	-0.194	-1.06	0.206
Porc_abs_af	%	1.340	2.322	1.571	-0.625	-9.558	5.976
DA_af	kg/m ³	2693.956	2578.694	120.327	0.958	1.309	1.254
TM_ag	in	1.000	1.478	0.552	-0.866	-6.526	5.653
TNM_ag	in	1.000	1.007	0.383	-0.017	3.373	-0.058
DAS_ag	kg/m ³	1327.000	1419.037	126.925	-0.725	0.351	-0.255
DAC_ag	kg/m ³	1466.000	1535.439	132.295	-0.525	7.057	-3.704
Porc_hum_ag	%	1.540	1.666	2.407	-0.052	-2.416	0.126
Porc_abs_ag	%	2.520	2.384	1.633	0.083	19.032	1.581
DA_ag	kg/m ³	2641.899	2632.632	120.982	0.077	-6.852	-0.525
Porc_opt_af	(0 a 1)	0.460	0.413	0.060	0.779	-0.657	-0.511
DO_mezcla	kg/m ³	1971.000	1948.160	206.973	0.110	-4.769	-0.526
Agua_corr	kg	166.597	200.306	25.732	-1.310	25.165	-32.966
Cemento_corr	kg	314.334	366.061	67.484	-0.767	-24.829	19.031
Arena_corr	kg	875.844	734.582	131.198	1.077	12.951	13.945
Grava_corr	kg	994.002	1008.736	119.555	-0.123	1.204	-0.148
a/c	adimensional	0.530	0.555	0.073	-0.336	-38.932	13.088
$\ln(\text{Edad})$	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de $f'c$ real de laboratorio (kg/cm ²)							271.030
Valor de $f'c$ predicho (kg/cm ²)							263.502
Error (kg/cm ²)							7.528
Error %							2.777

Anexo 16: Predicción para $f'c=280 \text{ kg/cm}^2$ muestra 2

UNIVERSIDAD TÉCNICA DE AMBATO FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA INGENIERÍA CIVIL							
TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"							
MODELO LASSO-3 ($f'_c=280 \text{ kg/cm}^2$) MUESTRA 2							
Fecha:	17 de mayo de 2026						
Elaborado por:	Karen Alexandra Mosquera Merchán						
Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.							
Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
Asent_hormigon	cm	8.000	7.047	2.923	0.326	2.443	0.796
Dens_cemento	gr/cm³	3.025	2.879	0.130	1.127	-3.657	-4.121
MF_af	adimensional	3.100	2.705	0.364	1.084	-2.804	-3.040
TM_af	cm	0.475	0.512	0.296	-0.126	-4.211	0.529
TNM_af	cm	0.236	0.196	0.149	0.265	-2.034	-0.538
DAS_af	kg/m³	1410.000	1517.676	124.096	-0.868	-5.423	4.705
DAC_af	kg/m³	1570.000	1646.206	120.781	-0.631	3.499	-2.208
Porc_hum_af	%	1.030	2.694	2.181	-0.763	-1.06	0.808
Porc_abs_af	%	1.030	2.322	1.571	-0.823	-9.558	7.862
DA_af	kg/m³	1410.000	2578.694	120.327	-9.713	1.309	-12.714
TM_ag	in	2.000	1.478	0.552	0.947	-6.526	-6.179
TNM_ag	in	1.000	1.007	0.383	-0.017	3.373	-0.058
DAS_ag	kg/m³	1450.000	1419.037	126.925	0.244	0.351	0.086
DAC_ag	kg/m³	1670.000	1535.439	132.295	1.017	7.057	7.178
Porc_hum_ag	%	2.600	1.666	2.407	0.388	-2.416	-0.938
Porc_abs_ag	%	0.640	2.384	1.633	-1.068	19.032	-20.332
DA_ag	kg/m³	1450.000	2632.632	120.982	-9.775	-6.852	66.980
Porc_opt_af	(0 a 1)	0.234	0.413	0.060	-2.977	-0.657	1.956
DOmezcla	kg/m³	1980.000	1948.160	206.973	0.154	-4.769	-0.734
Agua_corr	kg	174.651	200.306	25.732	-0.997	25.165	-25.090
Cemento_corr	kg	311.878	366.061	67.484	-0.803	-24.829	19.935
Arena_corr	kg	447.215	734.582	131.198	-2.190	12.951	-28.367
Grava_corr	kg	1460.096	1008.736	119.555	3.775	1.204	4.546
a/c	adimensional	0.560	0.555	0.073	0.073	-38.932	-2.858
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'c real de laboratorio (kg/cm²)							281.000
Valor de f'c predicho (kg/cm²)							252.271
Error (kg/cm²)							28.729
Error %							10.224

Anexo 17: Predicción para $f'_c=280 \text{ kg/cm}^2$ muestra 3

		UNIVERSIDAD TÉCNICA DE AMBATO FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA INGENIERÍA CIVIL					
TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"							
MODELO LASSO-3 ($f'_c=280 \text{ kg/cm}^2$) MUESTRA 3							
Fecha:		17 de mayo de 2026					
Elaborado por:		Karen Alexandra Mosquera Merchán					
Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.							
Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
sent_hormigon	cm	6.000	7.047	2.923	-0.358	2.443	-0.875
Dens_cemento	gr/cm ³	3.048	2.879	0.130	1.304	-3.657	-4.769
MF_af	adimensional	2.500	2.705	0.364	-0.562	-2.804	1.576
TM_af	cm	0.950	0.512	0.296	1.479	-4.211	-6.227
TNM_af	cm	0.475	0.196	0.149	1.864	-2.034	-3.792
DAS_af	kg/m ³	1306.000	1517.676	124.096	-1.706	-5.423	9.250
DAC_af	kg/m ³	1531.000	1646.206	120.781	-0.954	3.499	-3.338
Porc_hum_af	%	1.200	2.694	2.181	-0.685	-1.06	0.726
Porc_abs_af	%	0.610	2.322	1.571	-1.090	-9.558	10.418
DA_af	kg/m ³	2522.937	2578.694	120.327	-0.463	1.309	-0.607
TM_ag	in	1.500	1.478	0.552	0.040	-6.526	-0.263
TNM_ag	in	1.000	1.007	0.383	-0.017	3.373	-0.058
DAS_ag	kg/m ³	1395.000	1419.037	126.925	-0.189	0.351	-0.066
DAC_ag	kg/m ³	1551.000	1535.439	132.295	0.118	7.057	0.830
Porc_hum_ag	%	5.500	1.666	2.407	1.593	-2.416	-3.849
Porc_abs_ag	%	3.040	2.384	1.633	0.402	19.032	7.642
DA_ag	kg/m ³	2810.815	2632.632	120.982	1.473	-6.852	-10.092
Porc_opt_af	(0 a 1)	0.330	0.413	0.060	-1.386	-0.657	0.911
DO_mezcla	kg/m ³	1799.000	1948.160	206.973	-0.721	-4.769	3.437
Agua_corr	kg	204.146	200.306	25.732	0.149	25.165	3.755
Cemento_corr	kg	364.547	366.061	67.484	-0.022	-24.829	0.557
Arena_corr	kg	543.909	734.582	131.198	-1.453	12.951	-18.822
Grava_corr	kg	1122.763	1008.736	119.555	0.954	1.204	1.148
a/c	adimensional	0.560	0.555	0.073	0.073	-38.932	-2.858
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'_c real de laboratorio (kg/cm^2)							283.450
Valor de f'_c predicho (kg/cm^2)							228.699
Error (kg/cm^2)							54.751
Error %							19.316

Anexo 18: Predicción para $f'_c=300 \text{ kg/cm}^2$ muestra 1

		UNIVERSIDAD TÉCNICA DE AMBATO FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA INGENIERÍA CIVIL					
TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"							
MODELO LASSO-3 ($f'_c=300 \text{ kg/cm}^2$) MUESTRA 1							
Fecha:		17 de mayo de 2026					
Elaborado por:		Karen Alexandra Mosquera Merchán					
Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.							
Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
Asent_hormigon	cm	7.000	7.047	2.923	-0.016	2.443	-0.039
Dens_cemento	gr/cm ³	2.930	2.879	0.130	0.394	-3.657	-1.441
MF_af	adimensional	3.100	2.705	0.364	1.084	-2.804	-3.040
TM_af	cm	0.950	0.512	0.296	1.479	-4.211	-6.227
TNM_af	cm	0.236	0.196	0.149	0.265	-2.034	-0.538
DAS_af	kg/m ³	1512.000	1517.676	124.096	-0.046	-5.423	0.248
DAC_af	kg/m ³	1688.333	1646.206	120.781	0.349	3.499	1.220
Porc_hum_af	%	5.843	2.694	2.181	1.444	-1.06	-1.530
Porc_abs_af	%	3.890	2.322	1.571	0.998	-9.558	-9.540
DA_af	kg/m ³	2715.000	2578.694	120.327	1.133	1.309	1.483
TM_ag	in	1.000	1.478	0.552	-0.866	-6.526	5.653
TNM_ag	in	0.750	1.007	0.383	-0.670	3.373	-2.259
DAS_ag	kg/m ³	1432.000	1419.037	126.925	0.102	0.351	0.036
DAC_ag	kg/m ³	1527.333	1535.439	132.295	-0.061	7.057	-0.432
Porc_hum_ag	%	3.503	1.666	2.407	0.763	-2.416	-1.845
Porc_abs_ag	%	2.016	2.384	1.633	-0.226	19.032	-4.293
DA_ag	kg/m ³	2769.200	2632.632	120.982	1.129	-6.852	-7.735
Porc_opt_af	(0 a 1)	0.409	0.413	0.060	-0.071	-0.657	0.046
DO_mezcla	kg/m ³	2201.200	1948.160	206.973	1.223	-4.769	-5.830
Agua_corr	kg	200.000	200.306	25.732	-0.012	25.165	-0.300
Cemento_corr	kg	429.180	366.061	67.484	0.935	-24.829	-23.223
Arena_corr	kg	642.180	734.582	131.198	-0.704	12.951	-9.121
Grava_corr	kg	929.840	1008.736	119.555	-0.660	1.204	-0.795
a/c	adimensional	0.470	0.555	0.073	-1.155	-38.932	44.982
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'_c real de laboratorio (kg/cm^2)							303.468
Valor de f'_c predicho (kg/cm^2)							219.544
Error (kg/cm^2)							83.924
Error %							27.655

Anexo 19: Predicción para $f'c=300 \text{ kg/cm}^2$ muestra 2



UNIVERSIDAD TÉCNICA DE AMBATO

FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA

INGENIERÍA CIVIL



TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"

MODELO LASSO-3 ($f'_c=300 \text{ kg/cm}^2$)

MUESTRA 2

Fecha:

17 de mayo de 2026

Elaborado por:

Karen Alexandra Mosquera Merchán

Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.

Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coeficiente β	Contribución
Asent_hormigon	cm	10.000	7.047	2.923	1.010	2.443	2.468
Dens_cemento	gr/cm ³	3.150	2.879	0.130	2.091	-3.657	-7.646
MF_af	adimensional	2.920	2.705	0.364	0.590	-2.804	-1.655
TM_af	cm	0.475	0.512	0.296	-0.126	-4.211	0.529
TNM_af	cm	0.236	0.196	0.149	0.265	-2.034	-0.538
DAS_af	kg/m ³	1487.000	1517.676	124.096	-0.247	-5.423	1.341
DAC_af	kg/m ³	1636.000	1646.206	120.781	-0.085	3.499	-0.296
Porc_hum_af	%	1.630	2.694	2.181	-0.488	-1.06	0.517
Porc_abs_af	%	1.630	2.322	1.571	-0.441	-9.558	4.211
DA_af	kg/m ³	2617.000	2578.694	120.327	0.318	1.309	0.417
TM_ag	in	1.000	1.478	0.552	-0.866	-6.526	5.653
TNM_ag	in	0.750	1.007	0.383	-0.670	3.373	-2.259
DAS_ag	kg/m ³	1561.000	1419.037	126.925	1.118	0.351	0.393
DAC_ag	kg/m ³	1741.000	1535.439	132.295	1.554	7.057	10.965
Porc_hum_ag	%	1.940	1.666	2.407	0.114	-2.416	-0.276
Porc_abs_ag	%	1.940	2.384	1.633	-0.272	19.032	-5.179
DA_ag	kg/m ³	2657.462	2632.632	120.982	0.205	-6.852	-1.406
Porc_opt_af	(0 a 1)	0.353	0.413	0.060	-1.003	-0.657	0.659
DOmezcla	kg/m ³	1785.000	1948.160	206.973	-0.788	-4.769	3.759
Agua_corr	kg	201.710	200.306	25.732	0.055	25.165	1.373
Cemento_corr	kg	470.460	366.061	67.484	1.547	-24.829	-38.411
Arena_corr	kg	593.630	734.582	131.198	-1.074	12.951	-13.914
Grava_corr	kg	1086.160	1008.736	119.555	0.648	1.204	0.780
a/c	adimensional	0.429	0.555	0.073	-1.715	-38.932	66.775
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'_c real de laboratorio (kg/cm^2)							325.110
Valor de f'_c predicho (kg/cm^2)							272.326
Error (kg/cm^2)							52.784
Error %							16.236

Anexo 20: Predicción para $f'c=300 \text{ kg/cm}^2$ muestra 3

		UNIVERSIDAD TÉCNICA DE AMBATO FACULTAD DE INGENIERÍA CIVIL Y MECÁNICA INGENIERÍA CIVIL					
TEMA: "PREDICCIÓN DE LA RESISTENCIA A COMPRESIÓN SIMPLE DEL HORMIGÓN USANDO EL MODELO LEAST ABSOLUTE SHRINKAGE AND SELECTION OPERATOR (LASSO)"							
MODELO LASSO-3 ($f'_c=300 \text{ kg/cm}^2$) MUESTRA 3							
Fecha:		17 de mayo de 2026					
Elaborado por:		Karen Alexandra Mosquera Merchán					
Nota: Ingresar el valor de ln(Edad) debe ingresarse ya transformado.							
Variable	Unidad	Valor ingresado	Media (train)	Desviación Estándar (train)	Valor estandarizado	Coefficiente β	Contribución
sent_hormigon	cm	10.000	7.047	2.923	1.010	2.443	2.468
Dens_cemento	gr/cm ³	3.150	2.879	0.130	2.091	-3.657	-7.646
MF_af	adimensional	2.920	2.705	0.364	0.590	-2.804	-1.655
TM_af	cm	0.475	0.512	0.296	-0.126	-4.211	0.529
TNM_af	cm	0.236	0.196	0.149	0.265	-2.034	-0.538
DAS_af	kg/m ³	1487.000	1517.676	124.096	-0.247	-5.423	1.341
DAC_af	kg/m ³	1636.000	1646.206	120.781	-0.085	3.499	-0.296
Porc_hum_af	%	1.630	2.694	2.181	-0.488	-1.06	0.517
Porc_abs_af	%	1.630	2.322	1.571	-0.441	-9.558	4.211
DA_af	kg/m ³	2617.000	2578.694	120.327	0.318	1.309	0.417
TM_ag	in	1.000	1.478	0.552	-0.866	-6.526	5.653
TNM_ag	in	0.750	1.007	0.383	-0.670	3.373	-2.259
DAS_ag	kg/m ³	1561.000	1419.037	126.925	1.118	0.351	0.393
DAC_ag	kg/m ³	1741.000	1535.439	132.295	1.554	7.057	10.965
Porc_hum_ag	%	1.940	1.666	2.407	0.114	-2.416	-0.276
Porc_abs_ag	%	1.940	2.384	1.633	-0.272	19.032	-5.179
DA_ag	kg/m ³	2657.462	2632.632	120.982	0.205	-6.852	-1.406
Porc_opt_af	(0 a 1)	0.366	0.413	0.060	-0.787	-0.657	0.517
DO_mezcla	kg/m ³	1800.000	1948.160	206.973	-0.716	-4.769	3.414
Agua_corr	kg	201.710	200.306	25.732	0.055	25.165	1.373
Cemento_corr	kg	430.480	366.061	67.484	0.955	-24.829	-23.702
Arena_corr	kg	626.540	734.582	131.198	-0.824	12.951	-10.665
Grava_corr	kg	1086.160	1008.736	119.555	0.648	1.204	0.780
a/c	adimensional	0.469	0.555	0.073	-1.169	-38.932	45.513
ln(Edad)	adimensional	3.332	2.636	0.578	1.205	34.221	41.222
Intercepto del modelo (β_0)							202.843
Valor de f'_c real de laboratorio (kg/cm^2)							329.920
Valor de f'_c predicho (kg/cm^2)							268.534
Error (kg/cm^2)							61.386
Error %							18.606